



HAL
open science

Mise en place d'une méthodologie pour l'analyse de données GPS et accéléromètres afin d'améliorer la gestion du pâturage en élevage de bovins laitiers

Lucile Riaboff

► **To cite this version:**

Lucile Riaboff. Mise en place d'une méthodologie pour l'analyse de données GPS et accéléromètres afin d'améliorer la gestion du pâturage en élevage de bovins laitiers. Zootechnie. Le Mans Université, 2020. Français. NNT : 2020LEMA1010 . tel-02985391

HAL Id: tel-02985391

<https://theses.hal.science/tel-02985391v1>

Submitted on 2 Nov 2020

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

THESE DE DOCTORAT DE

LE MANS UNIVERSITE
COMUE UNIVERSITE BRETAGNE LOIRE

ECOLE DOCTORALE N° 602
Sciences pour l'Ingénieur
Spécialité : *Acoustique*

Par

Lucile RIABOFF

Mise en place d'une méthodologie pour l'analyse de données GPS et accéléromètres afin d'améliorer la gestion du pâturage en élevage de bovins laitiers.

Thèse présentée et soutenue à l'ESEO, Angers, le 29 Mai 2020
Unité de recherche : ESEO-tech - LAUM
Thèse N° : 2020LEMA1010

Rapporteurs avant soutenance :

Rémy Delagarde	Ingénieur de Recherche	INRAE AgroCampus Ouest - UMR Pégase
Jérôme Bindelle	Professeur	Gembloux Agro-Bio Tech - Nutrition et Elevage de Précision

Composition du Jury :

Président :	Guillaume Moreau	Professeur	Ecole Centrale de Nantes - UMR CNRS 1563 AAU
Examineurs :	Magali Jouven	Enseignant - Chercheur	INRA, Montpellier SupAgro - UMR SELMET
	David Rousseau	Professeur	Université d'Angers - LARIS
Dir. de thèse :	Guy Plantier	Professeur	ESEO - ESEO-tech LAUM
Co-dir. de thèse :	Sébastien Couvreur	Enseignant - Chercheur	ESA - URSE
	Sébastien Aubin	Enseignant - Chercheur	ESEO - ESEO-tech

Titre : Mise en place d'une méthodologie pour l'analyse de données GPS et accéléromètres afin d'améliorer la gestion du pâturage en élevage de bovins laitiers.

Mots clés : Vaches laitières, machine learning, accéléromètre, GPS, comportement, pâturage, bien-être animal, agroécologie.

Résumé : Les prairies, en déclin depuis les années 1970, peuvent jouer un rôle majeur dans la transition agroécologique compte tenu de leurs nombreux atouts. Leur valorisation par le pâturage est néanmoins complexe à mettre en œuvre et conditionne directement les bénéfices attendus. Des outils numériques se développent pour optimiser la gestion du pâturage dans le cadre de l'élevage de précision, un concept qui s'appuie sur la révolution numérique. Ces outils restent cependant marginaux et leur plus-value est généralement mal perçue par les éleveurs. Le comportement et la position des vaches laitières devraient servir de support au développement de ces outils car ils sont des indicateurs potentiels de l'état de la ressource sur la parcelle, de la santé et du bien-être des animaux. Des capteurs accélérométriques et GPS embarqués permettent de remonter automatiquement ces informations à condition de mettre en œuvre des techniques d'analyses adaptées. Ce travail de thèse consiste (i) à mettre en place une méthodologie permettant de remonter automatiquement les princi-

paux comportements des vaches laitières au pâturage à partir d'accéléromètres et (ii) d'évaluer le potentiel de cette méthodologie combinée à des données de position pour répondre aux applications envisagées. Le cadre méthodologique développé s'appuie sur des techniques de traitement du signal non explorées dans la communauté concernée, associées à une combinaison d'algorithmes qui met en jeu la complémentarité entre des méthodes de *machine learning* et des modèles probabilistes. Il garantit ainsi une prédiction fiable pour un large spectre de comportements des vaches laitières au pâturage. La preuve de concept réalisée témoigne également du potentiel de la méthodologie, combinée à des données de position des animaux, pour détecter des troubles de confort en lien avec les conditions de pâturage. Cette approche pourrait donc servir de support au développement d'outils d'aide à la décision pour l'optimisation de la gestion du pâturage, constituant ainsi un levier potentiel dans la transition agroécologique.

Title: Development of a methodology for the analysis of GPS and accelerometer data in order to improve grazing management of dairy cows in pasture-based systems.

Keywords: Dairy cow, machine learning, accelerometer, GPS, behaviour, grazing, animal welfare, agroecology

Abstract: Grasslands have been in decline since the 1970s but they can play a major role in the agroecological transition in view of the many assets they have to offer. However, their enhancement through grazing is difficult to implement and directly affects the expected benefits. In this respect, digital tools are being developed to optimise grazing management in the context of precision livestock farming, a concept based on the digital revolution. However, these tools remain marginal and their added value is generally poorly perceived by farmers. The behaviour and position of dairy cows should be used as a support for the development of these tools as they are potential indicators of the state of the resource on the paddock as well as the health and welfare of the animals. Embedded accelerometer and GPS sensors can automatically provide this information but appropriate analysis techniques are required. This thesis consists of (i) implementing a methodology to automatically collect the main

behaviours of dairy cows on pasture using embedded accelerometer sensors and (ii) evaluating the potential of this methodology combined with position data to meet the envisaged applications. The methodological framework is based on raw acceleration processing techniques which have not been explored in the concerned community, associated with a combination of algorithms which uses the complementarity between machine learning methods and probabilistic models. Thus, it provides reliable prediction for a wide range of dairy cow behaviours at grazing. The proof of concept also demonstrates the potential of the methodology, combined with animal position data, to detect comfort disorders related to grazing conditions. This approach should therefore support the development of decision tools for optimising grazing management, thus providing a potential lever in the agroecological transition.

Remerciements

Je souhaite d'abord remercier la région Pays-de-la-Loire, l'Association Nationale de la Recherche et de la Technologie ainsi que Terrena Innovation d'avoir financé ce projet de thèse. Je remercie également l'ESEO et le service AEI de Terrena de m'avoir accueillie pendant ces trois ans.

Je voudrais aussi remercier Rémy Delagarde et Jérôme Bindelle d'avoir accepté de rapporter ce travail de thèse. Mes remerciements s'adressent également à Guillaume Moreau pour avoir accepté de présider le jury ainsi qu'à Magali Jouven et à David Rousseau pour leur rôle d'examineur dans l'évaluation de ce travail.

Je tiens ensuite à remercier les membres de mon encadrement et du comité de pilotage du projet : Guy Plantier, Sébastien Aubin, Sébastien Couvreur ainsi qu'Aurélien Madouasse, Alain Chauvin, Etienne Goumand, Patrick Massabie et Nicolas Bédère. Merci pour la confiance que vous m'avez accordée durant ces trois ans. J'ai pu orienter ce projet dans la direction qui me convenait avec ma propre organisation de travail, ce qui me tenait particulièrement à cœur. En particulier, je souhaiterais remercier :

Guy Plantier pour sa bienveillance au cours de ces trois ans et pour ses propos toujours encourageants.

Sébastien Aubin pour son soutien. Merci pour tes conseils et ton aide lorsque j'ai été confrontée aux algorithmes qui fonctionnaient parfaitement bien hier mais plus du tout aujourd'hui ou à ces capteurs qui tenaient très bien trois jours de batterie sur les cinq prévus... De l'ESEO aux pubs irlandais, merci pour tous ces échanges qui m'ont permis d'avancer.

Sébastien Couvreur pour tout ce qu'il a pu amener au cours de ce travail de thèse. Merci pour ta pertinence et tes analyses toujours éclairées, y compris sur des domaines *a priori* assez éloignés de ton domaine d'expertise... Je te remercie également pour ta rigueur scientifique. On m'avait prévenue et je ne suis pas déçue.

Aurélien Madouasse qui a clairement joué le rôle d'un quatrième encadrant. Merci pour ta pertinence en comité de pilotage. Merci aussi pour la qualité de tes relectures d'article... j'imagine bien que toutes tes reformulations ont dû te demander un temps fou. Je suis sûre d'être maintenant un peu plus à l'aise en anglais, au moins en anglais scientifique, et par écrit, et c'est déjà ça... Alors merci !

Etienne Goumand pour m'avoir intégrée au sein de Terrena. Merci pour ta bienveillance et ton aide au cours des manips. Merci aussi à Patrick Massabie pour son accompagnement sur la fin de ma thèse. Merci également à Alain Chauvin pour ses avis éclairés et ses propos encourageants en comité de pilotage.

Et enfin Nicolas Bédère. Merci d'abord pour ton implication dans mon début de thèse, avec ce protocole expé à mettre en place en urgence, ces manips à réaliser, avec ou sans matos, avec ou sans main d'œuvre... Merci pour tout ce que tu m'as apporté ensuite, de tes topo stats et zootechniques à tes conseils relationnels... Un immense merci Nicolas.

Merci aussi à Hélène Leruste et à Sylvain Poggi pour leur pertinence aux comités de suivi de thèse. Je souhaiterais remercier particulièrement Sylvain pour son implication dans le travail de *machine learning*. Merci pour votre intransigeance. Je suis convaincue d'avoir passé un cap en *machine learning* et en programmation R, mais aussi d'avoir progressé en rédaction d'articles scientifiques.

Je voudrais aussi remercier tous ceux qui ont contribué aux expérimentations. Je remercie tout d'abord les éleveurs du GAEC Beloin, du GAEC de la Perrière, du GAEC de l'Harmonie, et bien-sûr Olivier Grimault du GAEC La Haute Roue. Merci à Damien Guitton et à Philippe Menard pour la conception du matériel en un temps record ... Merci à Charles-Elie Petiot pour son investissement colossal dans ces expérimentations. J'adresse enfin un énorme remerciement à ma stagiaire et amie Marie Roig-Pons. Cette période de ma thèse fut l'une des plus intenses mais j'en garde un souvenir extrêmement positif. Merci pour tes super codes R (et oui, tu es devenue une pro), pour l'organisation des manips, leur réalisation et bien-sûr, pour le partage de notre poisse mutuelle. Mais au final, tout est resté under control, tu ne trouves pas ?

Je remercie également ceux qui ont contribué à l'émergence d'un sentiment positif dans un climat plutôt terne... A Frédérique Jourjon, pour son attention sincère portée aux doctorants. A Mathieu Pouget pour m'avoir mis le pied à l'étrier au concours MT180 et à Emmanuelle Geslin pour ne pas tellement m'avoir laissé le choix de m'y inscrire ... ce double prix au Mans, il est aussi grâce à vous...

Je tiens à remercier les enseignants d'Oniris qui ont compté pour moi. A Véronique Cariou et Evelyne Vigneau pour m'avoir « vivement incitée » à poursuivre en thèse. Le traitement du signal accéléromètre n'a pas grand-chose à voir avec celui des données de perception des consos, ni avec celui des données métagénomiques (et encore que...) mais c'était

bien quand même ! Merci à Michel Séméno de m'avoir confortée dans mes ambitions d'enseignante-chercheuse. Et merci à Philippe Courcoux. Parce que le pédagogue des stats qui sait donner l'envie d'en faire son cœur de métier, c'est vous.

Je souhaite aussi remercier la promo 2018 de BTSA Oniris ... quelle chance j'ai eue de débiter mon expérience en enseignement par ces quelques mois avec vous. Je me suis donnée sans compter pour essayer de rendre les stats le plus accessible possible à des anti-matheux et vous me l'avez si bien rendu... Et merci à Naïna de m'avoir permis d'enseigner aux 3A en élevage de précision à l'ISA. Super expérience !

Je voudrais désormais remercier tous ceux qui ont pris part à mon environnement social, contribuant ainsi à mon équilibre psychique au cours de ces trois ans...

Merci d'abord à la team des doctorants, post-doctorants et collègues de l'ESEO : Valentin Besnard, Théo Richard, Romain Cormerais, Bader Boubaker, Romain Feron (d'ailleurs, ma session TeamViewer doit toujours être active sur ton PC...?), Frédéric Jouault, Olivier Camp, Fabien Chhel, Margaux Blanchard (je te le redis, heureusement qu'on n'a jamais été en cours ensemble...) et évidemment Jade Vanbuis. Merci à toi Jade pour tes analyses parfaitement justes et tes conseils éclairés qui en découlent. Merci aussi pour tous ces moments passés en dehors de l'ESEO, avec cette orientation assez binaire que je qualifierai de bière/bouffe *versus* crossfit. Ah le crossfit... Merci de m'avoir initiée à ce sport de cinglé qui consiste à continuer l'exercice jusqu'à ce que mort s'en suive. On adore !

Merci aussi à mes collègues de Terrena : A Pauline Loiseau et ses gâteaux, à Sophie Gironde et son humour « cru », à Maureen et sa bonne humeur. A Matthieu Haudebourg, pour sa répartie implacable et son humour pince-sans-rire. A Lucile Hervé, pour ses conseils éclairés de post-thésarde et sa gentillesse.

Je souhaite aussi remercier tous les doctorants de l'ESA. Je remercie particulièrement Soazig Di Bianco pour ces moments partagés de dépression positive qui consistent à rendre une situation chaotique profondément drôle par la mise en scène de son protagoniste. J'adresse évidemment un énorme remerciement à mon amie Léa K. TD, TP, projets, congrès, et maintenant la thèse. Je ne sais pas trop où on va, mais tel que c'est parti, on risque d'y aller ensemble. Merci pour ton soutien, ton humour et ta générosité, Léa K(K).

Merci, évidemment, aux copines de l'ambiance : Marie, Chloé, Pando, Clélia, Adèle, Adeline, Anne, Ato et (re) Léa K. Merci pour votre soutien, merci d'accepter mon hyperactivité « qui vous fatigue », de ne rien dire quand je suis en retard (donc tout le temps), et d'être profondément drôles (et un peu méchantes).

Merci à mes amis cavaliers : Julie, Clairette, Mélanie, Cécé, Céline, Juliette, Laetitia, Charlotte et Elodie. Encore merci, Elo, pour tout ce que tu as fait et continue de faire pour Type. Je n'arrivais plus à tout mener de front. Alors l'aboutissement de cette thèse, je te le dois à toi aussi. Et merci à mes irréductibles amis Rhône-alpins Léo, Margot, et bien-sûr Charlotte. Chacha, présente depuis toujours, soutien infailible. Nous ne sommes d'accord sur rien sauf peut-être sur l'essentiel. Merci d'être là. Pour ces trois années, pour toutes celles d'avant, et pour toutes celles qui suivront.

Aux amis du running : Léa, Chach, Vincent, Marine, Khmais ... Fractionné court ou long, ces deux entraînements passés par semaine avec vous sont toujours ressourçant...

Et enfin, parce que ce serait bien malhonnête de ma part de faire croire que ces trois ans se sont déroulés dans un parfait équilibre physique et mental, je souhaite remercier :

Mes anti-stress : Alexandre Astier, Alain Chabat, Jérôme Commandeur, Laurent Lafitte et évidemment Blanche Gardin. Merci Blanche pour votre humour caustique et moralisateur. C'est tellement rassurant de trouver plus sceptique et plus lucide que soit. Vraiment merci, car quand je ne sais plus trop pourquoi je suis là, avec vous, je le sais encore moins.

Mes (re)boosters : Freddie Mercury, Paul McCartney, Eric Clapton, Roger Hodgson... et bien sûr pour ces derniers mois, sincères remerciements à Léonard Cohen, Nina Simone et Amy Winehouse. Je ne dirai jamais que ces heures passées à rédiger mon mémoire en votre compagnie ont été un plaisir, mais vous avez su les rendre moins pénibles. Et surtout, il y a dans votre voix une énergie si communicative qu'elle me permet d'avancer lorsque ce n'est objectivement plus possible.

A Romuald, avec ou sans méditation...

A mes animaux : A Bulle et à Piana. A Type, à qui je dois des moments fantastiques sur cette saison de concours 2017. Pour la suite, j'ai fait de mon mieux pour t'accompagner... et je ne regrette rien. Et à Iron, évidemment. Parce-que l'esprit de compétition, la persévérance et l'intuition, une décennie plus tard, c'est toujours à toi que je le dois.

A mes parents, qui ont toujours été là. Merci de ne jamais avoir douté de moi. Merci d'accepter mes choix, parfois audacieux et un peu égoïstes.

Et à Thomas. Merci d'être là depuis bientôt 7 ans. Merci de si bien me correspondre. Merci de venir tempérer mon pessimisme. J'essaye d'être à la hauteur en retour, et je te promets de continuer.

Avant-propos

Ce travail de thèse, débuté le 1^{er} Avril 2017, s'inscrit dans le cadre du projet Vagabond qui implique la coopérative Terrena (Ancenis), le laboratoire ESEO-Tech LAUM (Ecole Supérieure d'Electronique de l'Ouest ; Angers), l'unité URSE (Ecole Supérieure d'Agricultures ; Angers) et l'UMR BioEpAR (Oniris INRAE ; Nantes). Ce projet s'intègre dans la démarche innovante « La Nouvelle Agriculture » entreprise par Terrena, qui consiste à concilier progrès et environnement, qualité et accessibilité, innovations et juste rémunération des producteurs.

Ce projet a été financé par la région Pays-de-La-Loire (Bourse N° 2016_01952), par l'Association Nationale de la Recherche et de la Technologie (CIFRE N° 2016_1502) et par Terrena Innovation.

Valorisation des résultats

Articles Scientifiques dans des journaux à comité de lecture

Acceptés

Riaboff, L., Poggi, S., Madouasse, A., Couvreur, S., Aubin, S., Bédère, N., Goumand, E., Chauvin, A., Plantier, G., 2020. Development of a methodological framework for a robust prediction of the main behaviours of dairy cows using a combination of machine learning algorithms on accelerometer data. *Computers and Electronics in Agriculture*. 169, 105179. <https://doi.org/10.1016/j.compag.2019.105179>

Riaboff, L., Aubin, S., Bédère, N., Couvreur, S., Madouasse, A., Goumand, E., Chauvin, A., Plantier, G., 2019. Evaluation of pre-processing methods for the prediction of cattle behaviour from accelerometer data. *Computers and Electronics in Agriculture*. 165, 104961. <https://doi.org/10.1016/j.compag.2019.104961>

Soumis

Riaboff L., Couvreur S., Madouasse A., Aubin S., Massabie P., Chauvin A., Bédère N. and Plantier G. Relationship between dairy cow behaviour and pasture characteristics explored with a methodology based on accelerometer and GPS data to highlight its potential for animal welfare monitoring. Soumis à *Biosystems Engineering* en Février 2020.

En preparation

Riaboff L., Couvreur S., Madouasse A. Prediction of behaviour of ruminants based on accelerometer data: a review. *Computers and Electronics in Agriculture*

Riaboff L., Madouasse A., Feuilloy M., Couvreur S., Relun A. Prediction of lameness in pastured dairy cows on the basis of behaviours and position derived from accelerometer and GPS data. *Journal of Dairy Science*

Riaboff L., Couvreur S., Madouasse A., Chauvin A. et Plantier G. Prédiction et géolocalisation des comportements principaux des vaches laitières à partir de capteurs accélérométriques et GPS embarqués, une approche pertinente pour améliorer la gestion du pâturage. *Revue INRA Productions Animales*.

Conférences internationales

Présentation orale

Riaboff L., Couvreur S., Madouasse A., Aubin S., Massabie P., Chauvin A., Bédère N. et Plantier G. Prédiction et géolocalisation des principaux comportements des vaches laitières à partir de capteurs accéléromètres et GPS embarqués, une approche pertinente pour relier le comportement avec les conditions de pâturage. 25e édition Congrès international francophone *Rencontre, Recherche, Ruminants*. 2020.

Riaboff, L., Aubin, S., Bédère, N., Couvreur, S., Madouasse, A., Goumand, E., Chauvin, A. and Plantier, G., 2019. Considering pre-processing of accelerometer signal recorded with sensor fixed on dairy cows is a way to improve the classification of behaviours. *European Conference on Precision Livestock Farming*. ECPLF 19, Cork, Ireland. 121–127.

Riaboff, L., Bedere, N., Couvreur, S., Aubin, S., Goumand, E., Magnier, J., Madouasse, A., Chauvin, A., Plantier, G., 2018. Influence of pasture characteristics and time of day on dairy cow behaviour predicted from GPS-data. *7 Gen. Meeting of European Grassland Federation*. EGF 23, Cork, Ireland. 803–809.

Poster

Riaboff L., Bedere N., Couvreur S., Aubin S., Goumand E., Magnier J., Madouasse A., Chauvin A. and Plantier G., 2018. Time-budget and location of activities in the paddock can be estimated from GPS-data. *International Symposium on the Nutrition of Herbivores*. ISNH, 10. Clermont-Ferrand, France.

Valorisation autre

Riaboff L., 2018. Le comportement des vaches laitières, déduit au moyen de données GPS et accéléromètres, est-il influencé par les caractéristiques de la pâture ? 16^{ème} carrefour de la recherche, ESA Angers, 30 janvier 2018.

Riaboff L., 2019. Mise en place d'une procédure pour l'analyse de données GPS et accéléromètres pour la valorisation de la prairie chez les bovins laitiers. Séminaire des doctorants ED SPI 2^{ème} année. Ecole Centrale de Nantes, Nantes, 5 Avril 2019.

Riaboff L. et Couvreur S., 2019. L'agro-écologie à l'épreuve du numérique : de la connaissance fine des pâturages et des comportements alimentaires des vaches à la construction d'une prise de conscience en action à l'ESA. Revue annuelle des nouveaux usages de l'ANRT. Agriculture connectée. AgroSup Montpellier, Montpellier, 12 Juin 2019.

Participation à la finale locale du concours « Ma thèse en 180 secondes », Le Mans, 9 Mars 2020 (prix du jury et prix du public).

Participation à la finale inter-régionale du concours « Ma thèse en 180 secondes », Brest, 12 Mars 2020.

Remontée automatique du comportement des vaches laitières à partir d'algorithmes de Machine Learning et de modèles probabilistes appliqués à des données accélérométriques : une approche prometteuse pour améliorer la gestion du pâturage. Riaboff L., Couvreur S., Aubin S., Madouasse A., Poggi S., Chauvin A., Massabie P., Plantier G. Journée agronomie, Plateforme Intelligence Artificielle, Angers, 1^{er} Juillet 2020.

Liste des abréviations

AccDy : Accélération Dynamique

AccSt : Accélération Statique

ANFIS : Adaptive Neuro-Fuzzy Inference System

CV : Validation croisée (cross-validation)

EA : Exploitation Agricole

ESB : Encéphalopathie Spongiforme Bovine

XGB : eXtreme Gradient Boosting

FAO : Food and Agriculture Organization of the United Nations (Organisation des Nations unies pour l'Alimentation et l'Agriculture)

FAWC : Farm Animal Welfare Committee (Comité sur le Bien-Être des Animaux d'Élevage)

FFT : Fast Fourier Transform (Transformation de Fourier Rapide)

GPS : Global Positioning System

HMM : Hidden Markov Model (Modèle de Markov Caché)

ICNH : Indemnité Compensatoire de Handicap Naturel

IGER : Institute of Grassland and Environmental Research

INRA : Institut National de la Recherche Agronomique

JDE : Jeu de données d'entraînement

JDT : Jeu de données test

kNN : k-Nearest Neighbors (k Plus Proches Voisins)

LDA: Linear Discriminant Analysis (Analyse Linéaire Discriminante)

LOOV : Leave-one-out validation

LR : Logistic Regression (Régression Logistique)

MS : Matière Sèche

ML : Machine Learning (Apprentissage Automatique)

NB : Naive Bayes classifier (classifieur Bayésien Naïf)

OBDA : Overall Dynamic Body Acceleration (Accélération Totale du Corps)

PAC : Politique Agricole Commune

PLF : Precision Livestock Farming (Elevage de Précision)

DSP : Densité Spectrale de Puissance

QDA : Quadratic Discriminant Analysis (Analyse Quadratique Discriminante)

RF : Random Forest (Forêt aléatoire)

RFID : Radio Frequency Identification (Identification de Radiofréquences)

SAU : Surface Agricole Utile

SHD : Stock d'Herbe Disponible

SMA : Signal Magnitude Area (Zone d'Amplitude du Signal)

SMS : Short Message Service

SVM : Support Vector Machine (Séparateurs à Vaste Marge)

UE : Union Européenne

UWB : Ultra Wideband system

VeDBA : Vector of the Dynamic Body Acceleration (Vecteur d'Accélération Dynamique du Corps)

VL : Vache Laitière

Table des matières

Introduction.....	1
Chapitre 1 : Etat de l'art.....	3
Partie 1. La valorisation des prairies par le pâturage en élevage de bovins laitiers : une pratique complexe aux atouts multiples pouvant être facilitée par le numérique	4
1. Modèles agricoles et prairies depuis l'après-guerre	4
2. Atouts des prairies en réponse aux nouveaux enjeux de l'élevage de bovins laitiers et rôle du numérique dans leur valorisation	10
3. Des outils numériques pour faciliter la gestion du pâturage	20
Partie 2. Vers la conception d'un outil d'aide à la gestion des systèmes herbagers : méthodes mises en œuvre pour remonter automatiquement des indicateurs pertinents pour détecter des événements au pâturage.	31
1. Le comportement et la position des vaches laitières au pâturage : des indicateurs pertinents pouvant être collectés à partir de capteurs accéléromètres et GPS	31
2. Méthodes utilisées pour classifier des comportements de ruminants à partir de capteurs accéléromètres embarqués.....	37
3. Evaluation des méthodes mises en œuvre pour classifier les comportements des ruminants.....	51
Références	57
Chapitre 2 : Questions et stratégie de recherche	65
1. Contexte de l'étude	65
2. Questions et objectifs	66
3. Stratégie mise en place.....	66
Références	69
Chapitre 3 : Evaluation de l'effet du traitement du signal brut sur les performances de prédiction des comportements des ruminants.....	70
1. Contexte de l'étude	70
2. Objectifs	71
3. Stratégie.....	71
4. Démarche	71
5. Résultats	73
6. Valorisation	73
Références	74
Chapitre 4 : Développement d'un cadre méthodologique assurant une prédiction robuste des comportements principaux des vaches laitières au pâturage, au moyen d'une combinaison d'algorithmes de <i>machine learning</i> sur des données accéléromètres.....	87
1. Contexte de l'étude	87
2. Objectifs	88

3. Stratégie.....	88
4. Démarche	88
5. Résultats	91
6. Valorisation	91
Références	92
Chapitre 5 : Relation entre le comportement des vaches laitières et les caractéristiques de la prairie explorée <i>via</i> une méthodologie basée sur des données GPS et accéléromètres en vue de souligner le potentiel de l'approche pour le suivi du bien-être animal.	110
1. Contexte de l'étude	110
2. Objectifs	110
3. Stratégie.....	111
4. Démarche	111
5. Résultats	113
6. Valorisation	113
Références	114
Chapitre 6 – Discussion	153
Partie 1. Mise en place d'un cadre méthodologique pour une prédiction robuste des comportements des vaches laitières, une approche à fort potentiel pour répondre à des problématiques autour du pâturage.....	154
1. Prédiction robuste de l'ensemble des comportements principaux des vaches laitières au pâturage à partir de données accéléromètres.....	154
2. Potentiel du cadre méthodologique combiné à des données de géolocalisation pour les applications envisagées.....	158
Partie 2. Conception d'un outil d'aide à la décision pour le pâturage à partir du cadre méthodologique développé	161
1. Volet développement : de la prédiction des comportements à la détection d'évènements au pâturage	161
2. Volet instrumentation : de la détection d'évènements au pâturage à un outil finalisé.....	164
Partie 3. Portée de l'outil au-delà des strictes applications envisagées : un système au service de différentes visions de l'agriculture.....	166
1. L'agriculture moderne et postmoderne, deux visions différentes de l'agriculture	166
2. Un outil numérique au service de deux visions de l'agriculture qui répondent à des volets différents de la transition agroécologique.	167
3. Outil numérique envisagé et agroécologie : quelles contradictions ?.....	169
Références	171
Conclusion	174
Références.....	176
Annexes	190

Introduction

L'élevage de bovins laitiers s'est profondément transformé à l'issue de la seconde Guerre Mondiale. A partir des années 1970, le mouvement d'intensification animale et fourragère s'est traduit par une diminution des surfaces en herbe, en particulier dans les régions de plaine (Béraud and Bouhaddi, 1996). Les systèmes d'élevage sont néanmoins remis en cause depuis une vingtaine d'années en raison des impacts environnementaux (Alexandratos, 2012) et des nouvelles attentes sociétales, orientées vers le bien-être animal et la qualité des produits (Delanoue and Roguet, 2015). A ce propos, les critiques émises envers les systèmes d'élevage semblent jouer en faveur d'un retour aux prairies (Huyghe, 2009). Cette revalorisation s'inscrit dans le contexte particulier de la transition agroécologique, qui vise à réviser les modes de production en utilisant des principes issus de l'écologie afin d'optimiser la productivité et de maximiser les services écologiques susceptibles d'être fournis par les agrosystèmes (Gliessman, 2007). La valorisation des prairies par le pâturage en élevage de bovins laitiers présente en effet de réels intérêts environnementaux, conduit souvent à de bonnes performances économiques et bénéficie d'une image positive auprès des consommateurs. La gestion du pâturage est néanmoins complexe à mettre en œuvre et conditionne directement les bénéfices attendus.

La fin des années 1990 est également marquée par l'essor du numérique, perçu comme l'un des moteurs de la croissance et du développement des sociétés modernes (Bravo, 2009). Le développement de l'agroécologie en œuvre depuis la fin des années 1990 s'inscrit donc dans un mouvement de numérisation du monde, questionnant le rôle potentiel du numérique dans cette transition (Bellon Maurel and Huyghe, 2017). Ces interrogations ont permis l'émergence de l'élevage de précision (Berckmans, 2014), un concept visant à mobiliser les nouvelles technologies pour optimiser les performances animales individuelles dans un meilleur respect du bien-être de l'environnement.. A ce propos, des outils pour faciliter le pâturage des vaches laitières et améliorer leur bien-être et leur santé se développent dans ce contexte mais leur plus-value pour les éleveurs n'est pas toujours bien perçue et leur fiabilité est rarement renseignée, justifiant de concevoir un nouvel outil.

La conception de ce type d'outils nécessite d'identifier des indicateurs pertinents à collecter sur les animaux pour répondre aux applications envisagées. A ce titre, le comportement des vaches laitières et leur position devraient permettre d'évaluer l'état de la ressource sur la parcelle (Ribeiro Filho et al., 2011; Werner et al., 2019), de détecter des troubles de santé (Siivonen et al., 2011) et des défauts de confort au pâturage (O'Driscoll et al., 2019).

Le comportement des animaux et leur position peuvent respectivement être remontés *via* des capteurs accéléromètres (Delagarde and Lamberton, 2015) et GPS (Putfarken et al., 2008) embarqués sur les animaux. Il convient néanmoins de mettre en œuvre des méthodes d'analyses adaptées pour remonter suffisamment d'informations sur le comportement de manière fiable (Rushen et al., 2012), quels que soient la période et les animaux équipés (validité des modèles ; Rahman et al., 2018).

Ce travail de thèse a été réalisé dans le cadre du projet Vagabond qui implique la coopérative Terrena (Ancenis), le laboratoire ESEO-Tech LAUM (ESEO ; Angers), l'unité URSE (ESA ; Angers) et l'UMR BioEpAR (INRAE-Oniris ; Nantes). Ce projet s'intègre dans la démarche innovante « La Nouvelle Agriculture » entreprise par Terrena et consiste à développer des outils pour les éleveurs afin de faciliter le pâturage des bovins laitiers et d'améliorer la santé et le bien-être. En particulier, ce travail de thèse vise à mettre en place une méthodologie à partir de capteurs accélérométriques et GPS embarqués pour remonter des informations sur le comportement et la position des vaches laitières dans les parcelles en vue répondre aux applications souhaitées. Les objectifs de recherche consistent à :

- ❖ Mettre en place une méthodologie qui permette de remonter un large spectre de comportements des vaches laitières au pâturage à partir de données accéléromètres brutes et qui reste valable quelles que soient la période et les vaches laitières équipées.
- ❖ Illustrer le potentiel de cette méthodologie pour répondre aux applications envisagées.

Le manuscrit est structuré en six chapitres. Le premier chapitre vise à (i) replacer les objectifs de la thèse dans le contexte de la transition agroécologique et de l'élevage de précision et (ii) à identifier les méthodes pour remonter des comportements à partir d'accéléromètres et d'en évaluer les limites. Le second chapitre pose les questions de recherche et présente la démarche scientifique adoptée. Viennent ensuite trois chapitres de résultats (chapitre 3, 4 et 5) qui visent respectivement à évaluer l'effet du traitement du signal accéléromètre brut sur les performances de classification des comportements, à identifier ensuite la combinaison optimale d'algorithmes pour répondre au problème posé et enfin à évaluer le potentiel de la méthodologie mise en place, combinée à la position des animaux, pour améliorer leur bien-être et leur santé au pâturage. Une discussion générale est enfin proposée afin (i) de revenir sur les verrous levés *via* la méthodologie développée et son potentiel pour les applications envisagées, (ii) d'identifier les étapes qui sont encore nécessaires au développement d'un outil commercialisable et (iii) d'évaluer la portée de l'outil selon deux visions de l'agriculture qui répondent chacune à différents volets de l'agroécologie. Quelques éléments de conclusion sont finalement proposés afin de répondre aux questions de recherche ayant fait l'objet de ce travail.

Chapitre 1 : Etat de l'art

Partie 1. La valorisation des prairies par le pâturage en élevage de bovins laitiers : une pratique complexe aux atouts multiples pouvant être facilitée par le numérique

1. Modèles agricoles et prairies depuis l'après-guerre

1.1 La révolution fourragère : « l'herbe, ça se cultive »

A l'issue de la seconde Guerre Mondiale, la France et l'Europe, appuyées par les USA (plan Marshall), ont souhaité moderniser leur agriculture pour garantir la sécurité alimentaire européenne. C'est dans ce contexte que la Politique Agricole Commune (PAC) a été créée en 1957 avec la priorité de satisfaire les besoins de la société. La modernisation de l'agriculture s'est traduite par une restructuration profonde de ce secteur, avec une concentration de la production, une spécialisation des élevages agricoles et une amélioration continue de la productivité du travail (Desriers, 2007). En élevage bovin, la spécialisation s'appuie sur la sélection de races adaptées, comme la vache Holstein en production laitière même si de nombreux systèmes d'élevage traditionnels locaux vont persister car mieux adaptés aux contraintes spécifiques des milieux (Pflimlin et al., 2009).

La révolution fourragère qui s'est opérée dans ce contexte traduit bien la volonté d'augmenter les productions en élevage d'herbivores par l'amélioration de la production de fourrage. Appuyé par des innovations agronomiques, un « paquet technologique » a ainsi été mis à disposition des éleveurs pour améliorer la fertilité des sols et la productivité des prairies. Les prairies naturelles, peu productives, ont alors été progressivement retournées pour être remplacées par des prairies temporaires¹ intégrées dans les rotations. Les surfaces en prairies temporaires vont ainsi doubler entre 1960 et 1980, avec une utilisation accrue de légumineuses fourragères pérennes (luzerne, trèfles, sainfoin). A noter que les progrès réalisés sur la culture des prairies, la robotisation et la mécanisation, n'auront pas été profitables de la même façon selon les régions. Ainsi, les éleveurs laitiers des zones aux sols pauvres et séchants (Bretagne, Pays de la Loire, Aveyron, Auvergne) en auront particulièrement profité tandis que ceux des zones herbagères et des zones de montagnes où l'herbe pousse naturellement auront de fait peu adhéré à cette révolution fourragère (Béranger and Liénard, 2006)

¹Prairie temporaire : surface herbagère semée depuis moins de 5 ans et dont la flore est composée d'un nombre d'espèces limitées aux espèces semées et aux adventices (Couvreur et al., 2018)

1.2 La « révolution blonde » : intensification des élevages de ruminants

Au cours des années 1970, la révolution fourragère commence à montrer certaines limites. D'une part, la récolte précoce d'une quantité abondante de fourrage humide de conservation difficile pénalise la production en réduisant l'ingestion des animaux dont les besoins alimentaires sont pourtant grandissants. D'autre part, les dépenses croissantes en intrants, en mécanisation et en investissements exigés par la révolution fourragère fragilisent l'économie des exploitations (Béranger and Lacombe, 2014). Le développement de variétés de maïs hybrides, plus précoces et dont la maturité coïncide avec les dates de récolte sous forme d'ensilage, lève ces points de blocage et offre ainsi de nouvelles perspectives à l'élevage de ruminants et de bovins laitiers en particulier (Carpentier and Cabon, 2011). Ces atouts vont faire du maïs le fourrage principal pour alimenter les bovins laitiers malgré sa faible teneur en azote, celle-ci étant palliée par une complémentation en tourteau de soja. Les surfaces en maïs en France vont ainsi tripler entre 1969 et 1975 au détriment des prairies permanentes², notamment en région de plaine. La spécialisation des élevages, découlant sur une augmentation de la taille moyenne des exploitations de ruminants (surface et cheptel), couplée à l'utilisation croissante du maïs dans les rations, aura permis à la collecte laitière d'augmenter de 40 % de 1970 à 1983 (Pflimlin et al., 2009).

L'intensification animale et fourragère s'est également maintenue après l'introduction des quotas laitiers par la PAC en 1984, l'objectif étant désormais de produire le quota avec un minimum d'animaux. En France, même si certains éleveurs ont préféré miser sur la plus-value des produits labellisés, en particulier dans les « régions défavorisées », les systèmes intensifs recherchant une forte productivité par animal et associés à des hauts niveaux d'intrants (fertilisation, concentrés, fourrage stockés) restent majoritaires sur cette période. Ces systèmes dominants vont alors marquer le paysage français pendant des décennies. On notera ainsi une diminution de 4.7 Mha de surface de prairies entre 1970 et 1994, soit près d'un quart de la surface initiale, alors que la Surface Agricole Utile (SAU) totale des exploitations agricoles n'aura diminué que de 6 % sur cette même période (Béraud and Bouhaddi, 1996). Seules les régions de montage ou de piémont, défavorisées au regard des conditions pédoclimatiques et du relief limitant souvent la mécanisation du travail du sol, auront maintenu leurs surfaces prairiales, en particulier les prairies permanentes.

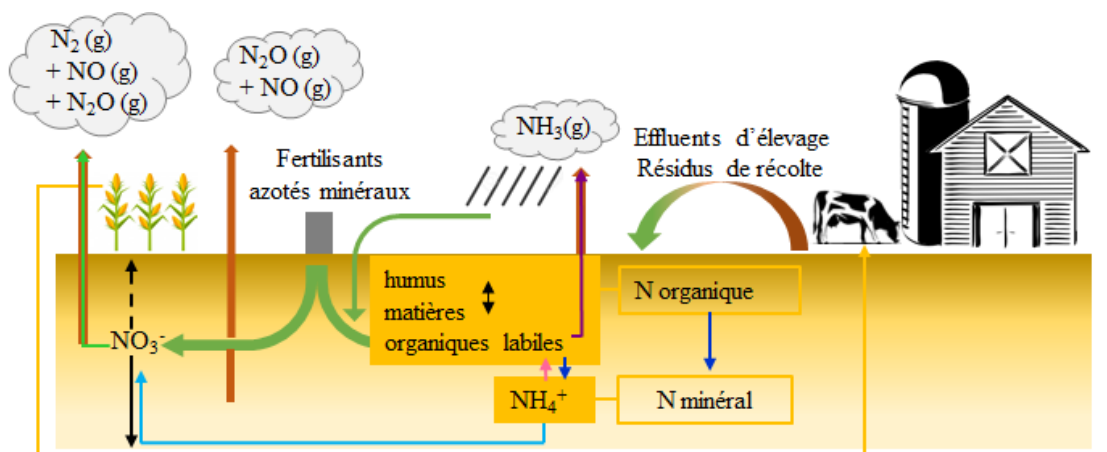
²Prairie permanente : surface herbagère de longue durée avec une flore diversifiée (Couvreux et al., 2018)

1.3 Remise en question des modèles agricoles : retour progressif des prairies dans le contexte de la transition agroécologique

1.3.1 Crise des modèles agricoles et émergence des nouveaux enjeux pour l'élevage de ruminants

❖ Prise de conscience collective des enjeux environnementaux

Dès les années 1980, des remises en question publiques sur les risques environnementaux associés aux modèles de production agricole développés depuis une vingtaine d'années se font entendre, comme en atteste le rapport de Jacques Poly, PDG de l'INRA (1978). Comme expliqué dans les rapports de l'Organisation des Nations unies pour l'Alimentation et l'Agriculture (FAO) (Alexandratos, 2012), les ruminants émettent du méthane (CH_4), un gaz à effet de serre issu de la fermentation dans le rumen et des effluents pendant leur stockage. L'élevage de ruminants contribue également au rejet de protoxyde d'azote (N_2O), un gaz à effet de serre puissant au pouvoir réchauffant très élevé. Comme illustré par la Figure 1, ces émissions de N_2O sont dues à l'apport en nitrates (NO_3^-) et en ions ammonium (NH_4^+) au cours de la fertilisation minérale des cultures. Les engrais minéraux participent aussi aux rejets d'ammoniac (NH_3) et au lessivage des nitrates, contribuant à la pollution de l'air et de l'eau (Figure 1). Enfin, une concentration excessive en azote et en phosphore dans les sols induit une eutrophisation des milieux dont les conséquences environnementales sur les écosystèmes sont parfois désastreuses, comme dans l'Ouest de la France (charges en azote organique de 130 kg/ha de SAU pour un excédent azoté national moyen de 29 kg/ha/an ; Agabriel et al., 2011).



Légende :

- | | | | |
|-----------------------------|---------------------------|------------------------------|-------------|
| → Entrée d'azote du sol | → Organisation de l'azote | → Volatilisation | → Ingestion |
| → Sortie d'azote du sol | → Nitrification | → Absorption par les plantes | |
| → Minéralisation de l'azote | → Dénitrification | → Lixiviation des nitrates | |

Figure 1. L'impact de l'élevage de bovins laitiers dans le cycle de l'azote.

Inspiré de : "Unifa : le cycle de l'azote," 2019

❖ Des attentes sociétales orientées vers le bien-être animal et la qualité des produits

Le bien-être animal et la consommation de produits animaux sont questionnés et sujets à controverse dans la société (Delanoue and Roguet, 2015). Les attentes sociétales en France (Delanoue and Roguet, 2015), en Europe (Dockes et al., 2007) et aux Etats-Unis (Cardoso et al., 2016) vont notamment vers des systèmes d'élevages permettant d'améliorer l'expression du comportement naturel des animaux.

A partir des années 1990, des préoccupations sur la qualité sanitaire des produits se font ressentir de la part des consommateurs. Ils expriment le besoin d'être rassurés sur les pratiques de production, notamment depuis les crises de l'encéphalopathie spongiforme bovine (ESB) en 1996 et 2000 qui semblent avoir entaché l'image de la filière bovine dans son ensemble (Pflimlin et al., 2009).

Depuis les années 2000, les consommateurs sont également à la recherche de qualité nutritionnelle et organoleptique, une tendance nouvelle dans un contexte où la quantité a longtemps primé sur la qualité. Une part croissante de consommateurs se tourne d'ailleurs vers des produits labellisés. En France, l'augmentation de 45 % de la consommation de lait conditionné labellisé agriculture biologique sur la période de 2013 à 2018, dans un contexte où la consommation globale de lait conditionné a diminué de 14 % en parallèle, illustre bien cette nouvelle tendance (FranceAgriMer, 2019).

❖ Des menaces économiques certaines

Depuis les années 2000, la mondialisation économique a entraîné une volatilité accrue des prix des matières premières agricoles. En particulier, le prix des intrants et autres moyens de productions en France a particulièrement augmenté (+ 30 à 35 %) sur la période de 2005 à 2012 (Pflimlin et al., 2009), un aspect pénalisant pour les modèles agricoles ayant recours à une mécanisation élevée et à un haut niveau d'intrants pour atteindre les niveaux de production recherchés.

1.3.2 Retour des prairies dans le cadre de la transition agroécologique

Les critiques émises envers les systèmes d'élevage depuis une vingtaine d'années semblent jouer en faveur d'un retour aux prairies. En 1993, la mise en place d'une prime au maintien des systèmes d'élevage extensifs par la PAC, visant à ralentir la disparition des surfaces prairiales, allait déjà dans ce sens. En 2004, la PAC souhaite freiner la disparition des surfaces de prairies conduites de manière extensive particulièrement, en encadrant la baisse des

surfaces prairiales à l'échelle des territoires. Pour cela, les Etats membres de l'Union Européenne (UE) doivent maintenir un ratio régional de prairies permanentes en limitant le retournement de celles dites « sensibles » (Nitsch et al., 2012). Même si ces dispositifs n'ont pas entravé la baisse en surfaces prairiales entre 2000 et 2014 (- 10%), cette dynamique tend néanmoins à ralentir puisque les surfaces de prairies se stabilisent depuis 2005 (Huyghe, 2009).

Cette revalorisation des prairies s'inscrit dans le contexte particulier de la transition agroécologique définie par Gliessman (2018) comme « l'intégration de la recherche, de l'éducation, de l'action et du changement qui apporte la durabilité à toutes les parties du système alimentaire : écologique, économique et social ». L'amélioration du bien-être et de la santé des animaux constitue également l'un des piliers de l'agroécologie (LIT OUESTEREL, 2019). Giessman complète enfin sa définition en expliquant que l'agroécologie est également participative, transdisciplinaire et orientée vers l'action. Cette transition est soutenue à l'échelle nationale et internationale comme en témoigne le rapport de la FAO proposé par de Schutter (2010). Le maintien et la valorisation des prairies par le pâturage en élevage de bovins laitiers sont revendiqués dans ce contexte, en raison de ses bénéfices environnementaux, économiques et sociétaux (Claveirole, 2016).

1.3.3 Emergence parallèle de la révolution numérique

La fin des années 1990 est aussi marquée par l'essor des technologies numériques avec le développement de l'informatique et d'internet. Cette révolution numérique entraîne des changements fondamentaux et profonds dans la manière dont les gens communiquent (courriels, réseaux sociaux, etc.). Elle donne également accès à de nouveaux services, facilités par le développement de l'intelligence artificielle et de la robotique (Venturi, 2015). Les technologies de l'information et des communications sont perçues comme l'un des moteurs de la croissance et du développement des sociétés modernes à tous les niveaux : compétitivité industrielle, partage de ressources, cohésion sociale, santé publique, éducation, culture, transport, sécurité (Bravo, 2009). L'essor de l'agroécologie depuis la fin des années 1990 s'inscrit donc dans un mouvement de numérisation du monde, questionnant ainsi le rôle potentiel des nouvelles technologies dans cette transition (Bellon Maurel and Huyghe, 2017).

Chapitre 1 – Partie 1

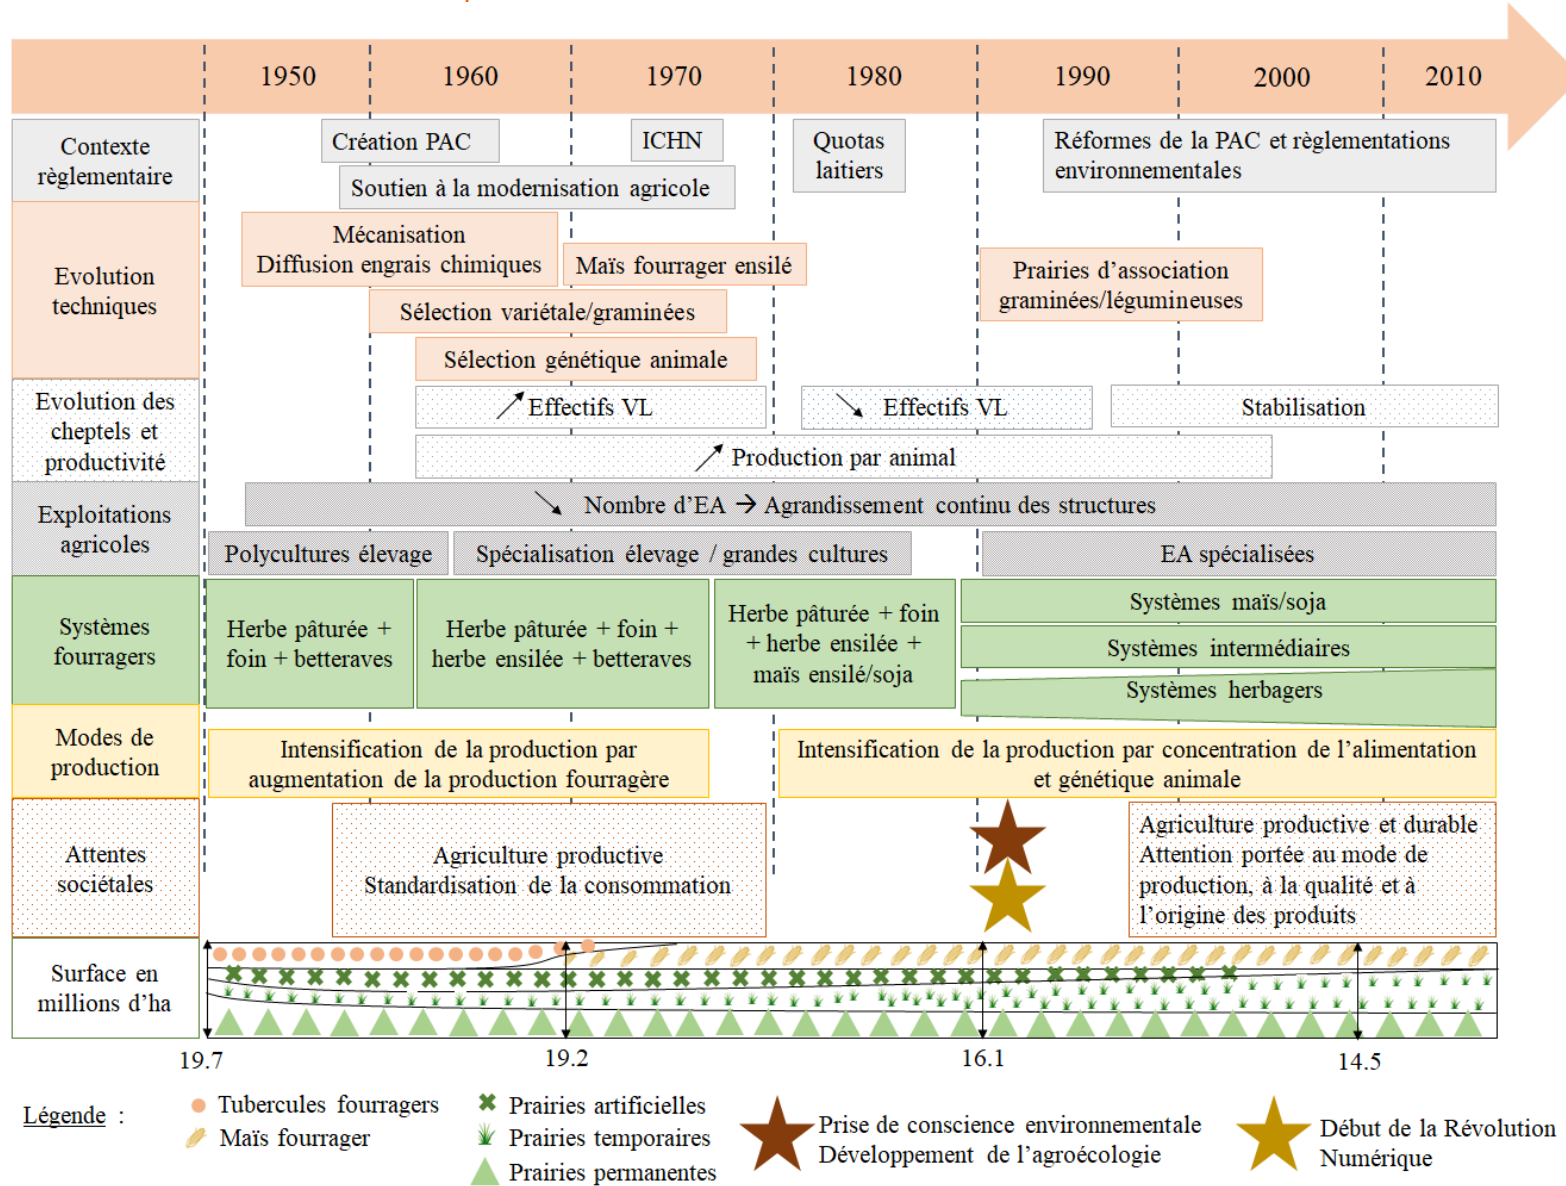


Figure 2. Evolutions majeures de l'agriculture et des exploitations agricoles laitières en lien avec l'évolution des surfaces de cultures fourragères en France. Inspiré de : Couvreur et al. Les prairies au service de l'élevage. 2018

SYNTHESE

La révolution fourragère qui s'est opérée à l'issue de la seconde Guerre Mondiale suivie de la « révolution blonde » basée sur le développement du maïs auront permis d'assurer la sécurité alimentaire à l'échelle européenne, priorité de la PAC à cette période. Néanmoins, les enjeux environnementaux soulevés par la FAO et les critiques d'une partie de la société à l'égard des modes de production conduisent désormais à une remise en question des modèles agricoles. La fin des années 1990 marque ainsi un changement de paradigme dans lequel la qualité prime désormais sur la quantité. Le développement de nouveaux systèmes visant à optimiser la productivité tout en maximisant les services écologiques susceptibles d'être fournis par les agrosystèmes s'inscrit dans le cadre de la transition agroécologique. Les prairies, en déclin depuis l'après-guerre, suscitent dans ce contexte un intérêt majeur. Enfin, la révolution numérique qui s'est opérée en parallèle soulève nécessairement des interrogations sur la contribution potentielle des nouvelles technologies dans la transition agroécologique. Il convient d'identifier désormais l'intérêt des prairies en réponse aux nouveaux enjeux de l'élevage de ruminants, particulièrement de bovins laitiers, mais également d'en exposer les limites en vue de mieux comprendre le rôle que peuvent jouer les nouvelles technologies dans leur valorisation.

2. Atouts des prairies en réponse aux nouveaux enjeux de l'élevage de bovins laitiers et rôle du numérique dans leur valorisation

2.1 Principe général de la valorisation de la prairie par le pâturage en élevage de bovins laitiers (Couvreur et al., 2018)

2.1.1 La prairie au cœur du système

L'objectif d'un système herbager est de maximiser l'utilisation de la prairie afin que sa valorisation garantisse l'essentiel de l'alimentation des animaux. La croissance de l'herbe étant hétérogène au cours de l'année (Figure 3) deux modes de valorisation de la prairie complémentaires sont réalisés afin d'assurer la quasi-autonomie alimentaire de l'exploitation, à savoir :

- Une consommation sur pied par le pâturage aux périodes favorables, c'est-à-dire au cours du printemps, des étés tempérés et de l'automne.

- Une récolte par fauche suivie du stockage des excédents destinés à une valorisation différée pendant les périodes où le pâturage est soit insuffisant pour couvrir les besoins des animaux, soit rendu impossible en raison d'une portance trop faible du sol.




Figure 3. Courbe de croissance annuelle schématisée d'une prairie et valorisation par le troupeau
D'après : Couvreur et al. Les prairies au service de l'élevage. 2018

Gérer un système herbager revient donc à optimiser la gestion de la prairie par l'utilisation conjointe de ces deux modes de valorisation de manière à atteindre un haut niveau d'autonomie alimentaire sans pour autant dégrader le potentiel des prairies.

2.1.2 Gestion du pâturage et des stocks fourragers conservés au cours de l'année

❖ Constitution du planning fourrager en début de saison

En début de saison, les besoins annuels en fourrage nécessaires pour nourrir les animaux sont évalués, en terme de stocks sur pieds comme de fourrages conservés. Cette estimation des besoins annuels sert de support à la constitution d'un planning fourrager dans lequel les surfaces à récolter, le mode de récolte et la nature des stocks sont prévus pour l'ensemble de la saison. A noter que ce calendrier est construit en vue de maximiser l'utilisation de stocks sur pieds, l'herbe pâturée étant l'aliment le plus économique.

❖ Gestion de la saison de pâturage

Au pâturage, l'éleveur a pour objectif de valoriser l'herbe en offrant un couvert dont la quantité et la qualité sont les plus adaptées possibles aux besoins des animaux. Cette gestion est a priori facilitée par les types de pâturage dans lesquels la consommation et la croissance sont réalisées

sur deux surfaces distinctes comme c'est le cas en pâturage tournant (Figure 4), technique souvent utilisée en élevage de bovins laitiers dans l'Ouest de la France (Leray et al., 2017).




Figure 4. Croissance et consommation de l'herbe dans le cas du pâturage tournant et aménagement du parcellaire associé. Inspiré de : Couvreur et al. Les prairies au service de l'élevage. 2018.

Dans le cas du pâturage tournant, l'objectif est donc de faire évoluer les animaux sur des parcelles dédiées au pâturage de sorte que l'équilibre offre/demande, exprimé en kilogramme de matière sèche (MS) par jour, soit quotidiennement obtenu :

$$\text{Offre (kg MS/j)} : \frac{\text{biomasse/ha} * \text{surface de la parcelle}}{\text{durée de séjour} * \text{Effectif}}$$

$$= \text{Demande (kg MS/j)} : \text{Quantité nécessaire/animal} * \text{Effectif}$$

L'éleveur peut ainsi mettre à disposition des animaux la quantité d'herbe qui leur est nécessaire en ajustant la surface des parcelles et/ou la durée de séjour selon la biomasse présente sur les prairies. La biomasse, difficilement mesurable, peut néanmoins être approximée par l'équation suivante :

$$\text{Biomasse/ha} \sim \text{Hauteur d'herbe (cm)} * \text{Densité/ha/cm}$$

Avec densité estimée ~ 250 kg de MS/ha/cm

Comme la hauteur d'herbe est directement mesurable sur les parcelles, la biomasse peut ainsi être estimée, permettant de déduire la surface et le temps de séjour adaptés aux animaux. Outre la quantité d'herbe offerte, l'éleveur doit également veiller à la disponibilité et à la qualité de l'offert afin de maximiser l'ingestion d'herbe au pâturage.

❖ Constitution et distribution différée des stocks fourragers

Le fauchage consiste à réaliser une coupe de la biomasse produite avant son conditionnement pour son stockage puis sa distribution à l'auge. Les stocks peuvent être soit conservés, soit laissés sur pieds. Dans le premier cas, l'herbe fauchée est conservée par voie humide (ensilage en silo, mi - fané enrubanné) ou par voie sèche (déshydraté, foin), l'objectif étant dans les deux cas de bloquer le plus tôt possible l'évolution de l'herbe après la fauche. La technique des stocks sur pieds consiste à accumuler de l'herbe sur pieds dans les prairies en fin de printemps afin de faire pâturer ce fourrage par les animaux lorsque la croissance de l'herbe commence à ralentir.

2.1.3 Entretien de la prairie pour garantir leur pérennité

L'entretien de la prairie s'intègre dans la gestion d'un système herbager puisqu'elle permet de garantir leur pérennité. Ainsi, les besoins de la prairie doivent être satisfaits par des apports suffisants en minéraux, principalement l'azote, le potassium et le phosphore, et en eau. Le couvert végétal doit également être entretenu *via* une bonne gestion de la fertilité du sol qui passe par les apports de la fertilisation mais aussi par une bonne gestion du pâturage et des fauches. Un sur-semis est parfois nécessaire pour enrichir la flore prairiale et une rénovation complète de la prairie peut éventuellement être envisagée pour remplacer une prairie dégradée.

2.2 Intérêts de la valorisation des prairies par le pâturage et complexité associée

2.2.1 Intérêts environnementaux, sociétaux et économiques des systèmes herbagers

Cette sous-partie a pour objectif de souligner les intérêts des prairies en réponse aux principaux enjeux de l'élevage de bovins laitiers. Les limites des prairies seront ensuite exposées.

❖ Intérêts environnementaux

Dans les élevages qui pratiquent le pâturage, les émissions de carbone sous forme de CO₂ sont compensées par la séquestration du carbone par les prairies (O'Mara, 2012). En stockant environ 1000 kg de carbone par hectare et par an, on estime que les prairies des systèmes herbagers de bovins laitiers assurent une compensation de 5 à 30 % des émissions de gaz à effet de serre issues de l'exploitation (Gac et al., 2010). Selon le type d'implantation des prairies et la place des légumineuses³ au sein de la flore du couvert, il est aussi possible de réduire la

³Les légumineuses peuvent rentrer en symbiose avec des bactéries du sol, les rhizobiums, capables de fixer l'azote atmosphérique (N₂). Les rhizobiums convertissent l'azote atmosphérique en ions ammonium (NH₄⁺) en utilisant la matière organique produite par la plante lors de la photosynthèse. Les ions NH₄⁺ sont ensuite convertis en nitrates (NO₃⁻), directement assimilables par la plante, *via* une réaction de nitrification assurée par d'autres bactéries.

fertilisation azotée sur les cultures (Schneider and Huyghe, 2015), limitant ainsi la volatilisation de l'ammoniac (O'Brien et al., 2012).

En raison d'un usage modéré d'intrants (pesticides, azote et phosphore), les exploitations qui valorisent la prairie génèrent moins d'eutrophisation des écosystèmes. A titre comparatif, une analyse complète du cycle de vie estime que l'eutrophisation totale des systèmes pâturant équivaut à 72 % de celle des systèmes confinés par unité de lait produit (O'Brien et al., 2012). Les prairies jouent aussi un rôle majeur dans la préservation de la qualité de l'eau en réduisant les effets de la pollution grâce à leur effet de filtre et limitent l'érosion du sol *via* l'apport d'un couvert permanent (Couvreur et al., 2018).

Les prairies contribuent enfin à la préservation de la biodiversité végétale, en particulier les prairies permanentes où plusieurs espèces coexistent. Les ruminants au pâturage participent également à la biodiversité puisque leurs préférences alimentaires, variables au cours de la saison, remettent en jeu en permanence la compétitivité entre les espèces végétales. Ils assurent également la dispersion des graines par voie endogène et exogène, élément moteur dans le maintien de la biodiversité (Rook and Tallwin, 2003). Enfin, la biodiversité s'envisage à l'échelle de la prairie mais aussi à celle du paysage. Les élevages herbagers garantissent ainsi l'entretien d'espaces ouverts, la conservation des bocages et la mosaïque des paysages (Agabriel et al., 2011).

❖ Intérêts sociétaux

Le pâturage est perçu par la société comme un mode de production sain et favorable à l'expression des comportements naturels des animaux (Delanoue and Roguet, 2015). De plus, les systèmes herbagers bénéficient généralement d'une bonne autonomie fourragère ce qui devrait contribuer à rassurer le consommateur sur son besoin légitime de sécurité par rapport aux aliments qu'il consomme (Pflimlin et al., 2001). L'herbe pâturée améliore globalement les qualités nutritionnelles du lait, en lien avec une plus faible concentration en acides gras saturés (C16 : 0; acide palmitique) et une plus forte concentration en acides gras de la série ω 3 (C18 : 3n-3; acide α -linoléique) (Chilliard et al., 2008). Enfin, l'herbe pâturée modifie également les qualités organoleptiques des produits finis. Les défauts d'oxydation sont par exemple moins présents dans ces produits en raison de la présence d'antioxydants naturels issus de la prairie (vitamine A et E) (Coulon et al., 2005).

❖ Intérêts économiques

Selon Peyraud et Delaby (2005), le maintien des prairies et la pratique du pâturage devraient constituer le socle des systèmes de production laitière durables puisque l'herbe pâturée est l'aliment le moins onéreux pour nourrir les vaches laitières. Cet aspect est particulièrement intéressant dans un contexte où le prix des produits agricoles diminue tandis que celui des aliments des animaux augmente (Pflimlin et al., 2001). Selon Chénais et al. (2001), l'herbe pâturée coûte ainsi 2 à 3 fois moins au kilogramme de matière sèche que les fourrages conservés et 6 à 7 fois moins que les aliments concentrés. Les coûts associés à la fertilisation minérale peuvent également être réduits par les déjections des animaux qui assurent des apports directs d'azote organique et minéral et par l'introduction des légumineuses. Enfin, les coûts liés à l'équipement (distribution des fourrages et concentrés) et à la mécanisation, correspondant à un tiers des charges des structures de l'Ouest de la France (Le Gall et al., 2001), sont généralement moins élevés dans les élevages pratiquant le pâturage.

La réduction théorique des coûts de production se traduit effectivement par une amélioration des revenus chez les éleveurs de bovins laitiers pratiquant le pâturage. D'après le bilan de campagne 2014 réalisé dans des exploitations de l'Ouest de la France, les éleveurs qui pratiquent le pâturage parviennent à dégager presque 50 % de revenu en plus par actif et 80 % en plus par hectare (Dieulot, 2013).

2.2.2 Complexité associée à la gestion du pâturage (Couvreur et al., 2018)

❖ Une gestion de l'herbe qui impacte directement les performances économiques

Comme expliqué précédemment, la conduite d'un système herbager nécessite de valoriser l'herbe pour nourrir directement les animaux mais également de constituer des stocks en fonction de la pousse effective de l'herbe, celle-ci étant variable au cours de la saison mais aussi d'une année sur l'autre. Une gestion pertinente du pâturage est primordiale puisqu'elle conditionne directement les performances économiques de l'exploitation. D'après une étude réalisée sur 200 élevages de vaches laitières en Irlande, l'utilisation de l'herbe par hectare explique 44 % de la différence nette en profit par hectare d'une ferme à l'autre (French et al., 2015). Selon Dillon (2011), chaque tonne de matière sèche d'herbe utilisée en plus correspond à une augmentation du profit net par hectare de 160 €, expliquant ainsi les écarts observés selon la gestion du pâturage réalisée. Afin de faciliter la prise de décision des éleveurs dans leur gestion du pâturage, des indicateurs ont été développés (Tableau 1). La hauteur d'herbe mesurée en sortie de parcelle sert notamment de support au calcul d'autres indicateurs comme le stock d'herbe disponible ou le nombre de jours d'avance.

Tableau 1. Indicateurs d'aide à la gestion de la conduite de pâturage

Indicateur	Définition et utilisation	Référence
Hauteur d'herbe en sortie de parcelle	Permet d'évaluer la pression de pâturage afin d'éviter le surpâturage ou au contraire le gaspillage.	Seuret et al., 2014
Hauteur d'herbe en entrée de parcelle	Critère d'alerte utilisé pour identifier des hauteurs d'herbe trop hautes, difficiles à pâturer.	Seuret et al., 2014
Stock d'herbe disponible (SHD)	- Calculé à partir des hauteurs d'herbe mesurées. - Représente la trésorerie fourragère au pâturage = quantité d'herbe accumulée au-dessus de 5 cm à un instant donné, exprimé en kg de MS par animal	Duru et al., 1999
Nombre de jours d'avance	- Calculé à partir du SHD et en estimant la consommation des vaches laitières à 16 kg MS/animal/jour - Correspond à la durée pendant laquelle l'éleveur va pouvoir nourrir son troupeau uniquement avec de l'herbe en absence de repousse. - Fait un état des lieux approximatif du stock sur pieds restant à un instant donné	Chénais et al., 2001 Couvreur et al., 2018
Croissance de l'herbe	- Estimée sur une période donnée en calculant la différence entre deux dates de mesures de hauteur d'herbe sur l'ensemble des parcelles de l'exploitation - Influence directement le SHD en compensant plus ou moins le prélèvement des animaux.	Seuret et al., 2014

❖ Des pratiques parfois néfastes pour l'environnement

Les intérêts environnementaux sont en réalité très dépendants de la manière dont les prairies sont utilisées. Une gestion du pâturage intensive, associée à un chargement animal élevé et des durées de pâturage trop longues, conduit par exemple à une diminution de la biodiversité, notamment dans les milieux peu productifs (< 2 t/ha) (Le Roux, 2008). Il a par ailleurs été démontré qu'un allongement trop important de la saison de pâturage (> 600 jours de pâturage par hectare) peut compromettre la pérennité de la prairie en raison du piétinement excessif des animaux et conduire à des pertes importantes d'azote nitrique par lessivage (Chénais et al., 2001).

❖ Des maladies favorisées par le pâturage

Même si le pâturage a plutôt tendance à réduire la prévalence d'événements de santé, il peut néanmoins favoriser l'apparition de maladies particulières. A titre d'exemple, une transition au pâturage au printemps mal gérée peut engendrer des maladies digestives ou métaboliques comme les tétanies d'herbage. Ces maladies sont associées au métabolisme minéral et se développent surtout au printemps chez des animaux en début de lactation soumis

à un stress thermique (vent, pluie, gelées) et à une consommation d'herbe jeune, aqueuse et pauvre en magnésium. Cette situation spécifique entraîne un déficit en magnésium induisant des troubles neuromusculaires ou digestifs pouvant aller jusqu'à la mort de l'animal ("La France Agricole. La tétanie d'herbage," 2005).

Certains parasites fréquemment rencontrés chez les bovins ont un cycle dont une phase se déroule sur les pâtures. Parmi les strongles majeurs on trouve *Ostertagia ostertagi* qui est un parasite gastro-intestinal. Une bonne gestion du risque parasitaire nécessite de prendre en compte l'immunité des animaux mais également de bien connaître le cycle de développement des parasites et ses conditions de développement (Chauvin, 2009). Le risque parasitaire est donc plus élevé au pâturage et directement conditionné par le planning mis en place par l'éleveur.

❖ Des conditions de pâturage parfois défavorables au bien-être

L'association entre bien-être animal et pâturage semble réalisée un peu trop hâtivement au regard des conditions de pâturage auxquelles les animaux sont parfois exposés. Ainsi, des conditions d'accès difficiles, associées à des aménagements du parcellaire non adaptés (mauvaise qualité de chemins...) peuvent favoriser l'apparition de certaines pathologies comme les boiteries. Des parcelles non appropriées (absence d'abris, de points d'eau ...) peuvent également générer des situations de stress chez les animaux au pâturage, comme un stress thermique (Schütz et al., 2010).

❖ Difficulté associée à la détection des événements sur les prairies (Couvreur et al., 2018)

Comme expliqué précédemment, des événements peuvent provoquer un stress, un inconfort ou une douleur chez les animaux au pâturage. Outre les troubles de confort, des événements de reproduction peuvent également se manifester sur les prairies (chaleur, vêlages, etc.). Quel que soit l'évènement, l'éloignement des animaux du site d'exploitation compromet le suivi par l'éleveur. Des visites régulières sur les prairies sont donc nécessaires pour s'assurer que tout est conforme.

2.3 Le numérique au service de l'élevage : concept de l'élevage de précision

2.3.1 Plusieurs définitions de l'élevage de précision mais des objectifs consensuels

Mettre le numérique au service de l'élevage s'inscrit dans le contexte de l'élevage de précision (*precision livestock farming* (PLF)), un concept développé dans les années 1995 en

Grande-Bretagne puis en Belgique (Meuret et al., 2013). Plusieurs définitions sont retrouvées dans la littérature mais il semblerait qu'il y ait en réalité deux visions de l'élevage de précision.

La définition la plus communément rencontrée correspond à celle de Berckmans, l'un de ses fondateurs. Selon lui, l'élevage de précision consiste à s'appuyer sur les nouvelles technologies pour optimiser les performances individuelles des animaux, appréhender des troubles de santé et de confort à l'échelle individuelle mais également à celle du troupeau *via* un suivi continu et automatisé, tout en limitant les impacts environnementaux de l'élevage (Berckmans, 2014). Ceci suppose (i) qu'un changement de comportement constitue la réponse initiale des animaux lorsqu'ils sont soumis à un challenge, (ii) que celui-ci peut être détecté automatiquement par des capteurs qui collectent de l'information sur les animaux de façon continue et (iii) que l'analyse de ces données *via* des algorithmes permet de fournir une alerte indiquant à l'éleveur les individus à surveiller et/ou un problème à l'échelle du troupeau. Le concept de l'élevage de précision selon Berckmans est illustré dans la Figure 5 ci-après. Dans ce cas, la rationalité du concept repose sur le fait que le suivi des animaux se complique avec l'augmentation de la taille des troupeaux, justifiant alors la mise en place d'un système de surveillance automatisé (Meuret et al., 2013). Pour cette raison, la PLF telle qu'elle est envisagée par Berckmans s'adresse prioritairement aux élevages intensifs aux bonnes capacités d'investissement (Bramley, 2009). Ceci explique certainement l'adoption rapide de ce concept en Allemagne, au Danemark, aux Pays-Bas et en Finlande (Meuret et al., 2013) où les troupeaux à grands effectifs dominant et où les capacités d'investissement sont élevées.

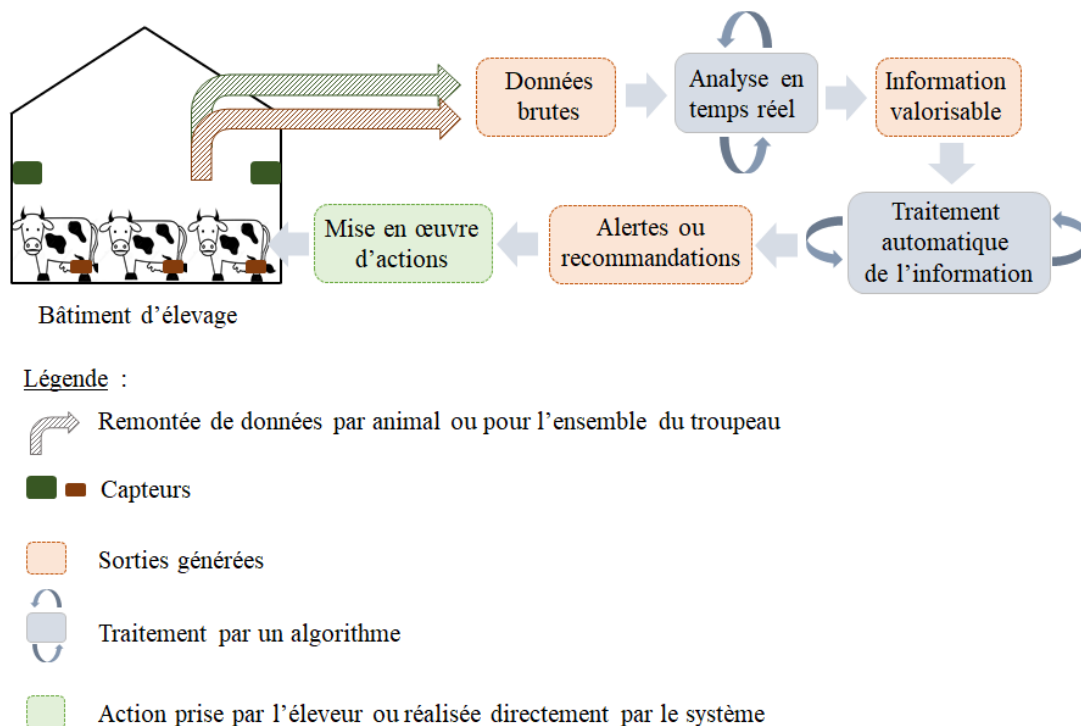


Figure 5. Principe de l'élevage de précision tel qu'il est décrit par Berckmans

La seconde définition correspond à celle proposée par Laca (2009). Selon lui, l'élevage de précision se réfère à l'exploitation de multiples niveaux d'hétérogénéité et de réponses non linéaires mesurées dans les processus de production *via* des nouvelles technologies en vue d'augmenter la rentabilité et de réduire les impacts environnementaux. Selon cette définition, le numérique a plutôt vocation à (i) générer de nouvelles données analysées *via* des algorithmes pour mieux comprendre les réactions des animaux et (ii) développer un bouquet de techniques permettant d'optimiser les performances en prenant en compte la diversité des milieux pour limiter les impacts environnementaux (Bellon Maurel and Huyghe, 2017).

Les objectifs de l'élevage de précision restent néanmoins consensuels puisqu'ils visent à optimiser les performances animales individuelles tout en améliorant le bien-être/la santé des animaux et en réduisant les impacts environnementaux. Dans les deux cas, la mise en œuvre de l'élevage de précision s'appuie (i) sur des capteurs (microphones, accéléromètres, caméras, capteur de température, de conductivité, etc.) pour mesurer différents paramètres en continu, (ii) sur des modèles mathématiques et biologiques pour extraire l'information à partir de la masse de données générées et (iii) sur des technologies de transfert de l'information pour remonter les données.

2.3.2 L'élevage de précision au service du pâturage des bovins laitiers : quels leviers possibles ?

L'élevage de précision peut certainement être appliqué au cas particulier de la valorisation des prairies par le pâturage. Ainsi, le suivi automatisé et continu des animaux *via* des capteurs pour détecter des troubles de confort/santé comme l'envisage Berckmans semble particulièrement intéressant pour diagnostiquer de façon précoce des événements qui auraient lieu sur les prairies, et donc à distance du site d'exploitation. Comme expliqué par Laca (2009), une compréhension fine des stratégies alimentaires des ruminants *via* des capteurs embarqués devrait servir au développement de systèmes exploitant au mieux l'hétérogénéité spatiale du couvert végétal pour optimiser les performances animales. Les technologies devraient également faciliter l'optimisation de la gestion des prairies temporaires en pâturage tournant en identifiant le moment optimal pour allouer une nouvelle parcelle aux vaches laitières (Werner et al., 2019). Enfin les technologies sont certainement un moyen de pallier certains impacts environnementaux inhérents au pâturage des animaux. Lush et al. (2018) équipent par exemple des moutons au pâturage avec un accéléromètre pour remonter des informations précises sur le comportement d'urination (distribution spatiale, fréquence de l'évènement, etc.) en vue d'adopter des pratiques qui réduisent les émissions de protoxyde d'azote.

SYNTHESE

Même si les prairies ont de nombreux atouts à faire valoir, leur gestion est particulièrement compliquée à mettre en œuvre. La gestion du pâturage est en effet dynamique, adaptative et inscrite dans un contexte très incertain. Bien que le pâturage soit plutôt favorable à de bonnes performances économiques, celles-ci dépendent surtout des décisions prises par l'éleveur pour assurer l'équilibre entre l'offre en herbe et le besoin des animaux. Le pâturage peut également favoriser le développement de certaines maladies, en lien avec des conditions de pâturage non adaptées. Le suivi du bien-être, de la santé et des événements de reproduction sur les prairies est aussi compromis par l'éloignement des animaux. Enfin, les bénéfices des prairies sur la qualité de l'air, de l'eau et du sol et sur la biodiversité sont à nuancer puisqu'une utilisation trop intensive peut être néfaste à l'environnement. A ce propos, l'élevage de précision qui consiste à mobiliser les nouvelles technologies pour optimiser les performances individuelles des animaux tout en améliorant le bien-être animal et en réduisant les impacts environnementaux des exploitations peut certainement être appliqué au pâturage. Il convient désormais de passer en revue les outils développés dans ce contexte en vue de faciliter la gestion du pâturage et le suivi des animaux sur les prairies puis d'en évaluer leur pertinence en vue de concevoir de nouveaux outils qui répondent aux attentes.

3. Des outils numériques pour faciliter la gestion du pâturage

3.1 Développement de premiers outils à partir de modèles de simulation

Des outils pour faciliter le pâturage des bovins laitiers ont été conçus dès les années 1980, comme des plannings de pâturage non informatisés. Des outils dynamiques ont ensuite été développés dès les années 2000 pour faciliter le calcul des indicateurs présentés dans le Tableau 1 et estimer leur devenir à court terme selon différentes options de gestion du troupeau et de pousse de l'herbe. Ces outils sont basés sur des modèles de simulation qui prennent en entrée des données mesurées sur les prairies, comme la hauteur d'herbe en sortie de parcelle, et des données sur les animaux (Seuret et al., 2014). Les principaux outils de simulation sont présentés dans l'Annexe I.

Des outils de simulation ont également été développés pour mieux appréhender certaines pathologies au pâturage. C'est par exemple le cas de Parasit'Info, un système expert qui permet d'identifier les périodes critiques de risque d'infestations par *Osterafia ostertagi* à

partir de données d'entrée standardisées sur les animaux et du planning de pâturage de l'éleveur (Chauvin et al., 2008).

Ces outils d'aide à la gestion du pâturage sont néanmoins peu utilisés par les éleveurs (Seuret et al., 2014) qui les jugent trop lourds, trop complexes et chronophages. Les éleveurs sont en effet en attente d'outils pratiques proposant des sorties immédiatement transposables en action (Dolecheck et al., 2013). Les outils numériques rentrant dans le cadre de l'élevage de précision devraient donc permettre de répondre aux nouvelles attentes des éleveurs.

3.2 Des outils développés dans le cadre de l'élevage de précision pour faciliter la gestion du pâturage et le suivi des animaux sur les prairies

Dans cette partie, seuls les outils développés pour le pâturage des vaches laitières ou présentant un intérêt pour répondre aux enjeux liés à la valorisation de la prairie sont présentés. On se limitera donc aux outils rentrant dans la définition de l'élevage de précision et qui visent (1) à faciliter la gestion du pâturage, (2) à détecter des troubles de santé/d'inconfort ainsi que des événements de reproduction sur les prairies.

3.2.1 Des outils basés sur les nouvelles technologies pour faciliter la gestion du pâturage

❖ Automatisation de la mesure de la biomasse

Comme expliqué précédemment, la hauteur de l'herbe sur les parcelles permet d'estimer la biomasse disponible et de déduire la plupart des indicateurs d'aide à la gestion du pâturage (Seuret et al., 2014). Sa mesure à l'herbomètre est cependant laborieuse et chronophage, justifiant le développement de technologies qui facilitent son acquisition. Des herbomètres électroniques ont ainsi été créés afin de convertir directement la hauteur d'herbe mesurée en centimètres comme le modèle Jenquip EC20® qui communique directement les mesures à une application via Bluetooth. L'herbomètre électronique GrassHopper® (True North Technologies) est également équipé d'un GPS intégré permettant de géolocaliser les mesures de hauteur d'herbe. Les mesures et coordonnées géographiques associées sont transférées automatiquement à une application pour Smartphone via Bluetooth. L'éleveur peut ainsi visualiser en temps réel les mesures prises sur les paddocks de son exploitation (French et al., 2015). L'usage de satellites se développe également, comme en témoigne le produit Pastures from Space® (<http://www.pasturesfromspace.csiro.au/>) qui fournit des informations hebdomadaires sur la croissance de l'herbe à l'échelle régionale et à l'échelle du paddock en

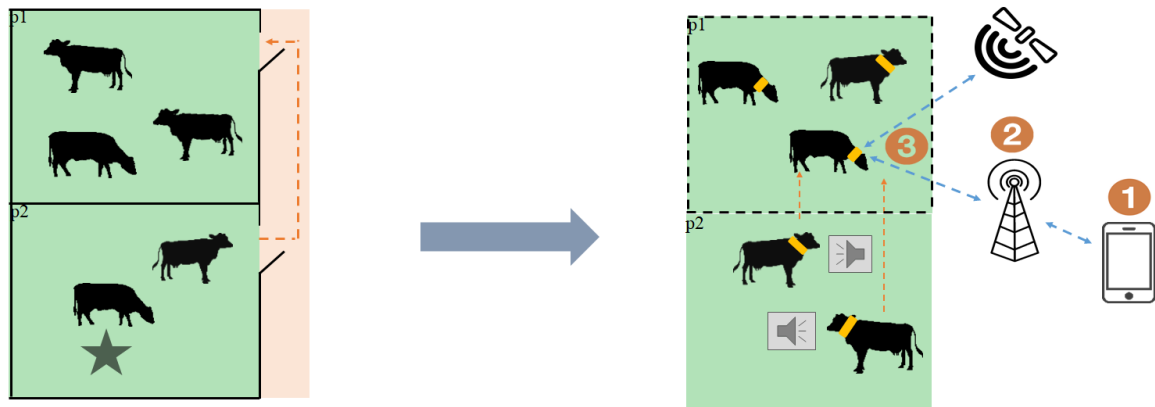
utilisant à la fois des mesures de biomasse obtenues par satellite et des données climatiques (Hills et al., 2016).

❖ Les barrières virtuelles : du concept à la solution finalisée

Les barrières virtuelles constituent l'unique avancée majeure dans le domaine de l'élevage de précision appliqué spécifiquement au pâturage (Hills et al., 2016). Selon Umstatter (2011), il s'agit « d'un système qui n'utilise pas de barrières physiques pour matérialiser l'espace disponible aux animaux ». Contrôler les animaux et les garder dans un espace défini sans barrières physiques est en réalité un concept datant de plus de 50 ans. Les premiers systèmes étaient basés sur l'émission/réception de signaux électromagnétiques entre un point central et un système embarqué sur l'animal (Brose, 1990). Plusieurs systèmes se sont ensuite succédé mais l'innovation majeure repose sur l'introduction du GPS embarqué sur les animaux par Marsh (1999). Lorsque leurs coordonnées géographiques se situent en dehors de l'espace qui leur est dédié, les animaux reçoivent alors un stimulus qui peut être sonore ou électrique. Le premier système est désormais commercialisé depuis 2016 (eShepherd®, Agersens) et son principe est illustré dans la Figure 6 ci-après.

Pâturage tournant classique

Pâturage tournant avec équipement du eShepherd®



Légende :

- Barrière physique
- - - Barrière virtuelle
- Orange rectangle: Chemin d'accès entre les deux paddocks
- - -> Déplacement des animaux
- ★ Intervention de l'éleveur au pâturage pour déplacer les animaux
- Yellow rectangle: Collier équipé d'un capteur GPS
- Speaker icon: Emission d'un stimulus pour les animaux en dehors de la zone
- ↔ Flux de données/informations
- 1 Saisie sur l'application smartphone de la zone dédiée aux animaux /remontée position des animaux
- 2 Communication relais assurée par une antenne relais
- 3 Réception des coordonnées géographiques

Figure 6. Principe des barrières virtuelles selon le système développé par Agersens

3.2.2 Des outils automatisés pour le suivi des animaux dans les prairies

❖ Suivi du bien-être et de la santé des animaux au pâturage

Les outils automatisés pour suivre le bien-être et la santé des animaux au pâturage sont tous basés sur un principe similaire. Ils consistent à remonter des informations sur le comportement des animaux, comme la rumination, l’ingestion au pâturage, le repos en position couché et/ou debout, etc. Le temps passé et la fréquence des comportements remontés sont ensuite mesurés. Ces informations sont ensuite utilisées par d’autres algorithmes qui détectent le moment où la situation est perçue comme anormale. Une alerte signalant un trouble de santé ou un défaut de confort chez l’animal concerné est alors envoyée à l’éleveur. La spécificité de chacun des outils repose sur les comportements prédits par chacun des systèmes, et par suite sur le capteur utilisé et sa position sur l’animal. Des exemples de systèmes commercialisés basés sur ce principe sont présentés dans le Tableau 2 ci-après.

Tableau 2. Exemple de systèmes de détection automatique de troubles du confort chez les vaches laitières au pâturage

Nom système (fabricant)	Capteur	Position capteur	Comportements remontés
Time’Live® (Medria®)	Accéléromètre	Collier	Repos, ingestion au pâturage, rumination et postures « couché » et « debout »
CowAlert® (IceRobotic®)	Accéléromètre	Membre	Posture « couché »
Smartbow® (Zoetis®)	Accéléromètre	Oreille	Rumination
Track A Cow® (Dairymac®)	Podomètre	Membre	Activité et postures « couché » et « debout »

❖ Outils d’aide à la détection des évènements de reproduction (Allain et al., 2012)

Plusieurs systèmes de détection des chaleurs sont disponibles sur le marché. La concentration en progestérone dans le lait est couramment utilisée par les systèmes de détection automatique de chaleur, une baisse indiquant le début de l’évènement. La mesure de l’activité physique est aussi utilisée par certains systèmes puisqu’un pic d’activité est observé à cette période (Zebari et al., 2018). D’autres variables peuvent également être mesurées, comme l’acceptation du chevauchement qui est un des signes caractéristiques. Lorsqu’une chaleur est détectée, une alerte est envoyée à l’éleveur par SMS ou sur logiciel selon les systèmes. En fonction du stade physiologique de l’animal, l’éleveur prendra ou non la décision d’inséminer l’animal. Des exemples de systèmes commercialisés basés sur ce principe sont présentés dans le Tableau 3.

Tableau 3. Systèmes de détection automatique de chaleurs retrouvés sur le marché

Nom système (fabricant)	Variable mesurée	Capteur
Heatphone® (Medria®)	Activité et rumination	Accéléromètre
AfiTag® (Afirmilk®)	Activité	Podomètre
Herd Navigator® (DeLaval®)	Concentration de la progestérogène	Analyseur permettant de mesurer la concentration en progestérogène dans les échantillons de lait prélevés automatiquement au moment de la traite
HeatWatch II® (cowchips®)	Chevauchement	Capteurs de pression

La température vaginale est un indicateur souvent mesuré pour détecter les vèlages. La température corporelle de la vache, comprise entre 38.5°C et 39.2°C, s'élève en effet les trois derniers jours de gestation pour diminuer le jour du vèlage. Les mouvements de la queue sont aussi utilisés pour détecter cet évènement puisque le soulèvement de la queue pendant une durée déterminée constitue un signe caractéristique de l'imminence du vèlage. Les contractions abdominales ou les transitions entre les positions couché et debout, plus fréquentes à l'approche du vèlage, sont également utilisées. Des algorithmes de détection basés sur ces variables génèrent ensuite une alerte vocale ou par SMS pour avertir l'éleveur de l'imminence de l'évènement. Des exemples de systèmes de détection automatique des vèlages commercialisés qui fonctionnent sur ce principe sont présentés dans le Tableau 4.

Tableau 4. Systèmes de détection automatique du vèlage commercialisés

Nom système (fabricant)	Variable mesurée	Capteur
Vel'Phone® (Medria®)	Température vaginale	Capteur thermique
Vel'Box® (Gènes Diffusion®)	Température vaginale	Capteur thermique
Smart Vel® (Evolution®)	Mouvement de la queue	Accéléromètre
Alert'Vel® (ALB Innovation®)	Mouvement de la queue	Accéléromètre
Agrimonitor® (Databel®)	Contractions abdominales	Capteur de pression
Podometre Plus® (Afirmilk®)	Transition position couchée/debout	podomètre

3.3 Limites actuelles des outils développés dans le cadre de l'élevage de précision

Plusieurs critères peuvent être utilisés pour évaluer les outils à disposition sur le marché (Dolecheck et al., 2013). Ici, l'analyse est réalisée de la même façon que celle proposée par Rutten et al. (2013). L'évaluation proposée consiste à :

- (1) **Identifier le niveau d'information** apporté par le système parmi les quatre niveaux distingués par Rutten et al. (2013) (Figure 7). Le premier niveau d'information apporté par les systèmes correspond à une information compréhensible (hauteur d'herbe en cm, nombre de chevauchements par jour, niveau d'activité moyen, etc.) obtenue à partir d'un algorithme qui utilise les données brutes du capteur. Le second niveau correspond à une information directement transposable en action (détection d'un début de chaleur, d'un inconfort, etc.) obtenue *via* un algorithme de détection basé sur les sorties de l'algorithme précédent. A partir de ce niveau, le système peut être considéré comme un outil d'aide à la décision. Le troisième niveau correspond à une information transposable en action qui prend en compte des données connexes (données économiques ou relatives à la stratégie de l'éleveur). Enfin, le dernier stade repose sur le niveau d'automatisation de la décision. Selon les applications, la décision peut soit être prise par l'éleveur, soit être gérée directement par le système.
- (2) **Evaluer la fiabilité du système** *via* des indicateurs appropriés pour le système en question.

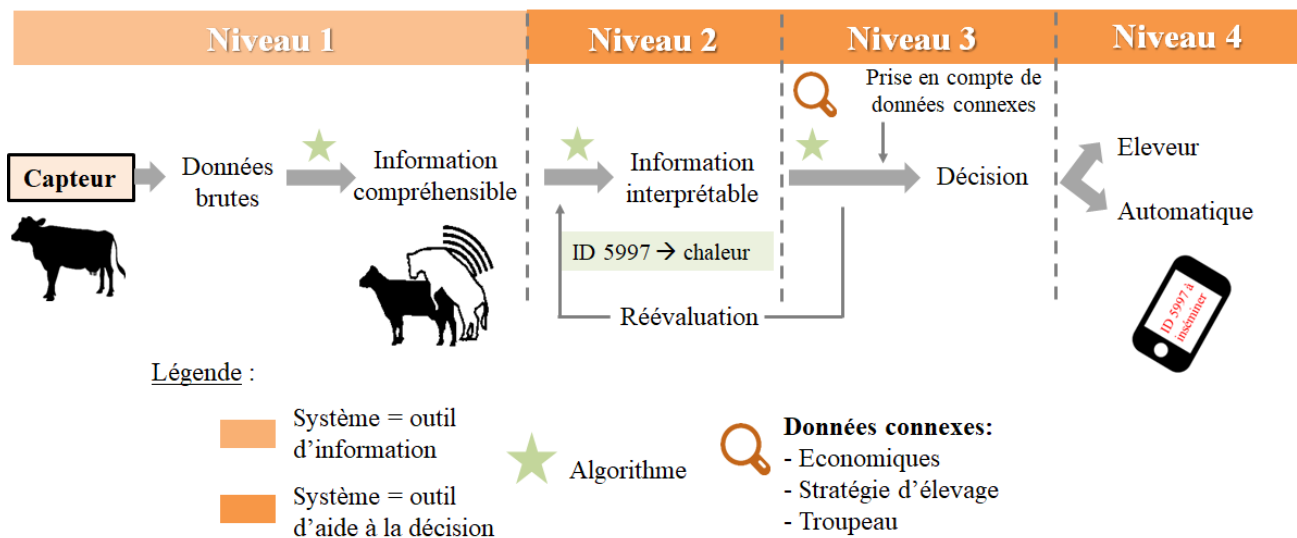


Figure 7. Différents niveaux d'information des systèmes de surveillance

Inspiré de : Rutten et al. Overview of published sensor systems for detection of oestrus and lameness in dairy cows. *Proceedings of the 6th European Conference on Precision Livestock Farming*. 2013

3.3.1 Evaluation des outils basés sur les nouvelles technologies pour faciliter la gestion du pâturage

❖ Mesure automatisée de la biomasse : des outils assurant un gain de temps

Les outils automatisés de mesure de la biomasse permettent d'obtenir directement la hauteur d'herbe en centimètre, correspondant au premier niveau d'information selon Rutten et al. (2013). L'analyse et l'interprétation restent à la charge de l'éleveur : ce ne sont donc pas des outils d'aide à la décision. Parmi ces technologies, une validation de l'herbomètre GrassHopper® a été publiée dans la littérature (McSweeney et al., 2015). Les mesures ont été comparées avec celles de l'herbomètre manuel de référence Jenquip®. Bien qu'une corrélation de 0.998 ait été obtenue, les mesures ont été réalisées uniquement en Irlande dans des conditions de pâturage particulières. Des tests dans des conditions différentes sont désormais réalisés en France, en Belgique et aux Pays-Bas (French et al., 2015).

❖ Les barrières virtuelles : un système de simplification des tâches

Le potentiel des barrières virtuelles pour l'aide à la gestion du pâturage est largement mis en avant dans la littérature (French et al., 2015; Umstatter, 2011) mais ce concept se limite actuellement à une simplification des tâches associées à la rotation des animaux dans les parcelles. Les barrières virtuelles ne sont donc pas des outils d'aide à la décision. La fiabilité des barrières virtuelles s'évalue quant à elle sur deux aspects :

- (1) La fiabilité de la position des animaux obtenue par GPS. La résolution spatiale du GPS est en effet primordiale puisque le stimulus envoyé à l'animal est fonction de la position enregistrée. Selon Umstatter (2011), la résolution spatiale des GPS utilisés par les différents systèmes testés n'est pas suffisante pour ce type d'application. La résolution spatiale du GPS utilisé par Agersens® n'est pas documentée.
- (2) La fiabilité de la réponse de l'animal au stimulus. La réponse de l'animal conditionne directement la faisabilité du concept. A ce propos, les stimuli électriques envoyés aux animaux fonctionnent convenablement mais soulèvent des questions d'éthique (Umstatter, 2011). Des études comportementales s'intéressent par conséquent à d'autres types de stimuli mais ceux-ci semblent difficilement compréhensibles pour les animaux, ce qui compromet la fiabilité du système.

3.3.2 Evaluation des outils basés sur les nouvelles technologies pour suivre automatiquement le bien-être, la santé, et les évènements de reproduction

- ❖ Plus-value discutable des outils de suivi du bien-être et de la santé des vaches laitières au pâturage

Les outils de surveillance du bien-être animal et de la santé des animaux au pâturage assurent la détection d'un évènement anormal : ce sont donc des outils d'aide à la décision (Rutten et al., 2013). L'analyse du problème reste cependant à la charge de l'éleveur (trouble de santé/confort, challenge interne/externe, etc.). De plus, les données sont systématiquement traitées au niveau individuel alors qu'elles pourraient être agrégées sur l'ensemble des animaux équipés (Rutten et al., 2013). Cette approche permettrait de détecter un défaut de confort général, en lien avec l'environnement ou les conditions de pâturage.

Les systèmes de détection d'anomalies au pâturage présentés précédemment n'ont été validés que pour le premier algorithme, *i.e.*, celui qui permet d'interpréter la donnée brute pour obtenir une information compréhensible. L'évaluation consiste à mesurer la corrélation ou la concordance entre les comportements remontés par l'algorithme et les comportements observés (référence). Parmi les outils pris comme exemple précédemment, une évaluation des performances a pu être trouvée pour les systèmes Track A Cow®, Smartbow® et CowAlert® (Borchers et al., 2016). Les coefficients de corrélation obtenus pour chacun de ces trois systèmes sont présentés dans le Tableau 5.

Tableau 5. Evaluation de la qualité de la prédiction des comportements des systèmes Track A Cow®, Smartbow® et CowAlert®

D'après : Borchers et al., 2016. A validation of technologies monitoring dairy cow feeding, ruminating, and lying behaviors. *Journal of Dairy Science*. 2016

Système	Comportement	Coefficient de corrélation	
		Pearson	Concordance
Track A Cow®	Ingestion	0.93	0.79
	Couché	0.99	0.99
Smartbow®	Rumination	0.97	0.96
CowAlert®	Couché	0.99	0.99

La concordance entre les comportements prédits et observés est satisfaisante pour ces trois systèmes. Néanmoins, l'absence de validation des algorithmes de détection à l'origine des alertes ne permet pas d'estimer leur fiabilité et par suite leur plus-value pour un éleveur. A noter qu'aucune évaluation du système Time'Live® n'a été trouvée dans la littérature.

- ❖ Fiabilité et plus-value des systèmes de détection des évènements de reproduction (Allain et al., 2012)

Les outils d'aide à la détection des chaleurs et des vèlages détectent automatiquement les évènements concernés : ce sont donc des outils d'aide à la décision. De plus, ils amènent tous des informations de niveau 4 puisqu'ils envoient systématiquement une alerte à l'éleveur lorsque l'évènement est détecté (Allain et al., 2013, 2012). Aucun des systèmes ne prend cependant en compte des informations complémentaires internes ou externes à l'élevage pour cibler les recommandations (Rutten et al., 2013).

Contrairement aux algorithmes de détection des vèlages, les performances des algorithmes de détection des chaleurs sont généralement publiées dans la littérature. Dans les deux cas, des systèmes performants sont néanmoins proposés sur le marché. Les performances publiées dans la littérature des systèmes précédents sont fournies dans le Tableau 6 et dans le Tableau 7 pour les chaleurs et les vèlages, respectivement.

Tableau 6. Performances de systèmes de détection automatique de chaleurs

Nom système (fabricant)	Sensibilité (%)	Spécificité (%)	Précision (%)	Référence
Heatphone® (Medria®)	62		87	Chanvallon et al., 2012
AfiTag® (Afimilk®)	71		71	Chanvallon et al., 2012
Herd Navigator® (DeLaval®)	93 – 99	94		Friggens et al., 2008
HeatWatch II® (cowchips®)	69 – 92		95	Allain et al., 2012

Tableau 7. Performances de systèmes de détection automatique des vèlages

Nom système (fabricant)	Sensibilité (%)	Spécificité (%)	Précision (%)	Référence
Vel'Phone® (Medria®)	100		100	Chanvallon et al., 2012c
Podometre Plus® (Afimilk®)	83		71	Allain et al., 2012

3.4 Identification des besoins en nouveaux systèmes au regard de l'existant dans le contexte de la transition agroécologique

3.4.1 Vers un système d'aide à la conduite du pâturage pour mieux valoriser les prairies

Aucun système automatisé d'aide à la décision pour la gestion du pâturage n'est actuellement proposé aux éleveurs bien que ce type d'outils soit certainement un moyen de répondre à leurs attentes (Seuret et al. 2014). En pâturage tournant, ils permettraient de sécuriser la prise de décision *via* une estimation fiable et automatique de l'état de la ressource sur les parcelles (Werner et al., 2019). Selon ces auteurs, ces outils permettraient ainsi de mieux appréhender le moment où les ressources au pâturage viennent à manquer et où l'allocation d'une nouvelle parcelle est nécessaire, contribuant ainsi à l'optimisation conjointe de l'utilisation de l'herbe et des performances animales recherchée dans la transition agroécologique.

3.4.2 Vers un système fiable du suivi du bien-être et de la santé des animaux au pâturage

Si des systèmes fiables d'aide à la détection des événements de reproduction sont déjà à disposition sur le marché, la tendance est différente pour les outils de suivi des troubles de santé/confort des animaux au pâturage. Ainsi, la plus-value de ces outils est difficilement estimable puisque les alertes envoyées à l'éleveur ne sont pas validées scientifiquement dans la littérature. La nature du trouble détecté n'est pas non plus mentionnée alors qu'un minimum d'information est nécessaire pour évaluer le degré d'urgence de l'intervention. Enfin, une agrégation des données collectées individuellement permettrait de fournir des alertes à l'échelle du troupeau (Rutten et al., 2013) en vue de détecter des anomalies liées à l'environnement des animaux (conditions climatiques, intrusion d'animaux extérieurs sur la parcelle, etc.) ou aux conditions de pâturage (ressources limitantes, aménagements inappropriés, etc.). En garantissant un suivi du bien-être des vaches laitières au sens des cinq libertés fondamentales ("Farm Animal Welfare Committee (FAWC)," 2011), un tel outil devrait contribuer à l'amélioration du bien-être animal, un des piliers de la transition agroécologique.

SYNTHESE

Cette partie a mis en exergue (1) l'absence d'outils automatisés pour l'aide à la conduite du pâturage et (2) la plus-value limitée des outils de détection de troubles de santé/confort chez les vaches laitières sur les prairies. Ces outils ont pourtant un rôle majeur à jouer dans la transition agroécologique, justifiant le développement d'un nouvel outil capable d'assurer ces fonctions. Pour cela, il est nécessaire d'identifier un ou plusieurs indicateurs pertinents pour détecter les évènements ciblés (ressources limitantes, évènement stressant). Une fois identifiés, il convient de cibler les capteurs les plus adéquats et les différentes techniques d'analyse pouvant être mises en œuvre pour obtenir les indicateurs souhaités à partir des données brutes des capteurs.

Partie 2. Vers la conception d'un outil d'aide à la gestion des systèmes herbagers : méthodes mises en œuvre pour remonter automatiquement des indicateurs pertinents pour détecter des événements au pâturage.

1. Le comportement et la position des vaches laitières au pâturage : des indicateurs pertinents pouvant être collectés à partir de capteurs accéléromètres et GPS

1.1 Intérêt de remonter des informations sur le comportement et la position des vaches laitières au pâturage

1.1.1 Le comportement des vaches laitières au pâturage comme indicateur de l'état de la ressource sur les parcelles, du bien-être et de la santé

❖ Des comportements indicateurs de l'état de la ressource sur les parcelles

Comme expliqué précédemment, le couvert végétal devient moins préhensible en dessous d'une certaine hauteur d'herbe. La prise alimentaire en masse est alors plus faible par unité de temps (Delagarde et al., 2010). Les vaches adaptent en conséquence leur comportement alimentaire pour palier à cette diminution de la vitesse d'ingestion. Le temps de pâturage est généralement augmenté (+ 49 minutes/jour à partir du 3ème jour du cycle ; Delagarde et al., 2010). Le temps de pâturage est aussi un indicateur de la qualité de l'offert puisque Ribeiro Filho et al. (2011) observent une augmentation du temps de pâturage avec la diminution en limbes (+ 12 minutes de pâturage par cm de feuilles perdu). Néanmoins, cette adaptation est dépendante de la motivation des animaux, ceux-ci pouvant au contraire cesser tout comportement d'ingestion pendant une durée déterminée lorsque le couvert devient excessivement difficile à pâturer (Delagarde et al., 2010). Les animaux augmentent également la fréquence des bouchées pour palier à la diminution de la vitesse d'ingestion (75.3 *versus* 80.3 mouvements/min pour un couvert de 9 cm et 5 cm de hauteur, respectivement ; Gibb et al., 1999). Werner et al. (2019) observent également des sessions de pâturage plus longues chez les animaux ayant à disposition un offert inférieur à leur capacité d'ingestion. Néanmoins, ces adaptations du comportement alimentaire ne convergent pas nécessairement d'une étude à l'autre puisqu'elles dépendent du statut physiologique des animaux (Gibb et al., 1999) ou encore de la conduite de pâturage (Kennedy et al., 2009). Même si le comportement d'ingestion

est certainement un indicateur pertinent pour rendre compte de l'état du couvert, il semble donc nécessaire de collecter des informations complémentaires.

A ce propos, le comportement de rumination est certainement intéressant puisque la durée journalière, la fréquence des mouvements de la mâchoire et la durée moyenne des sessions de rumination sont diminuées lorsque les vaches ont à disposition un offert qui équivaut à 60 % de leur capacité d'ingestion (Werner et al., 2019). Néanmoins, ces adaptations ne vont pas toujours dans ce sens et sont aussi influencées par la conduite du pâturage (Kennedy et al., 2011).

Les vaches laitières ayant disposition un offert inférieur à leur capacité d'ingestion semblent enfin se coucher moins souvent que leurs congénères. Le comportement couché est donc un dernier indicateur potentiel de l'état de la ressource sur la parcelle (O'Driscoll et al., 2019; Werner et al., 2019).

❖ Des comportements indicateurs de l'état de santé des vaches laitières

Les vaches laitières modifient certains de leurs comportements lorsqu'elles sont affectées par des troubles de santé. A ce propos, il convient de s'intéresser au comportement de rumination puisque les vaches passent moins de temps à ruminer lorsqu'elles sont atteintes de maladies métaboliques (acidose ruminale : - 97 min/jour ; DeVries et al., 2009), en cas de maladies infectieuses (mammites cliniques ; Siivonen et al. , 2011) et en cas de troubles de la locomotion (boiteries : - 10 % ; Almeida et al., 2008). Ces études ont été réalisées avec des vaches laitières au bâtiment mais il semble légitime de considérer le comportement de rumination comme indicateur potentiel de l'état de santé des animaux au pâturage.

Le comportement d'ingestion des vaches laitières semble également pertinent pour détecter différents types de troubles. Les animaux augmentent en effet le temps dédié à la prise alimentaire dans le cas de maladies métaboliques (acidose ruminale : + 85 min/jour ; ration mixte de fourrages et concentrés ; DeVries et al., 2009) au même titre que lorsqu'ils sont atteints de maladies infectieuses (mammites ; ration à base d'ensilage ; Siivonen et al., 2011). Le nombre de repas et leur durée sont aussi diminués dans le cas de troubles de la locomotion (boiteries : - 12.7 % ; Almeida et al., 2008). Ces études ont été réalisées au bâtiment et mériteraient d'être validées en système pâturant, mais il paraît néanmoins cohérent de s'intéresser au comportement d'ingestion au pâturage comme indicateur potentiel de l'état de santé des animaux.

Des informations sur la posture couchée méritent aussi d'être collectées. En particulier, une diminution du temps passé couché est un indicateur de certaines maladies

métaboliques (acidose ruminale ; DeVries et al., 2009) et de maladies infectieuses (mammites ; Siivonen et al., 2011). Les vaches laitières affectées par un trouble de la locomotion ont au contraire des sessions en position couchée plus longues que les animaux sains (89.3 min *versus* 80.7 min respectivement ; Yunta et al., 2012).

Les troubles de locomotion conduisent généralement à une altération du déplacement (Blackie et al., 2011) ce qui justifie de prendre aussi en compte le comportement de marche.

Finalement, les signes d'expression corporelle sont modifiés en cas de maladies infectieuses (mammites ; Siivonen et al., 2011) et de troubles de la locomotion (boiteries : + 3.91 min de temps dédié au comportement se lécher/se frotter ; Almeida et al., 2008). Dans ce dernier cas, les vaches laitières reçoivent également plus d'interactions positives de la part des congénères et génèrent moins d'interactions négatives envers les autres animaux du troupeau (Galindo and Broom, 2002).

❖ Des comportements indicateurs d'un défaut de confort

Wechsler (1995) explique qu'une adaptation en réponse à un challenge interne ou externe se manifeste initialement par une modification du comportement des animaux. Ainsi, un manque de confort lié aux conditions de pâturage devrait pouvoir s'appréhender à partir du comportement des vaches laitières.

A ce propos, il semblerait que la position couchée soit un indicateur majeur du bien-être, sa privation générant des réponses attestant d'un stress physiologique (Munksgaard and Simonsen, 1996). Les vaches se couchent par exemple moins souvent et sur des sessions plus courtes lorsqu'elles subissent un stress nutritionnel au pâturage (O'Driscoll et al., 2019). Les vaches exposées au froid (3.4 °C), au vent (7.1 km/h) et à la pluie (3.0 mm/h) (Webster et al., 2008) ou encore à des températures élevées (Schütz et al., 2010) passent aussi moins de temps couché que leurs congénères.

Enfin, les comportements sociaux sont aussi modifiés en présence d'un stress. Schütz et al. (2010) observent plus de comportements agressifs entre les vaches lorsque les zones ombragées à disposition sont limitantes, un comportement renforcé lorsque la température extérieure s'élève et que l'humidité relative diminue.

Chacun des challenges conduit donc à une modification sur plusieurs niveaux, justifiant de collecter une large gamme de comportements. En particulier, il paraît primordial de remonter des informations sur le comportement d'ingestion au pâturage, sur la rumination et sur le repos, en s'attachant à bien discriminer les postures « debout » et « couché » pour ces deux dernières activités.

1.1.2 La position des vaches laitières au pâturage comme indicateur de l'état de la ressource sur les parcelles, du bien-être et de l'état de santé

- ❖ La distribution spatio-temporelle des vaches laitières, indicatrice de l'état de la ressource

L'utilisation de l'espace par les animaux est certainement un autre indicateur pertinent de l'état du couvert. En Californie, Larson-Praplan et al. (2015) ont par exemple équipé 12 bovins avec un GPS et observé un lien entre la distribution spatiale de l'activité de pâturage et la qualité de l'offert. Ainsi, un fourrage de faible qualité, en lien avec des températures élevées à la période estivale, conduit à des fortes concentrations de pâturage au niveau des arbres. Au contraire, un offert de très bonne qualité en début de printemps motive les animaux à pâturer sur des sites plus larges. De la même façon, une étude réalisée en Allemagne montre que les animaux pâturent les zones qui ont été délaissées les mois précédents lorsque la ressource se raréfie (Putfarken et al., 2008). Enfin, la distance parcourue par les bovins semble augmenter lorsque la biomasse diminue (Manning et al., 2017), justifiant de s'intéresser à la position des animaux pour en déduire leurs déplacements. Il y a donc certainement un lien entre l'offert disponible et la distribution spatiale des vaches sur les parcelles. A ce titre, combiner des informations sur le comportement des animaux avec des données de position semble prometteur pour évaluer l'état de la ressource à disposition (Andriamandroso, 2017).

- ❖ L'utilisation des éléments structurants des parcelles comme indicateur des conditions climatiques

Les éléments structurants des parcelles sont utilisés de façon différente selon les conditions climatiques. Williams et al. (2019) ont par exemple montré avec un système de radio-identification (RFID) qu'un temps nuageux retardait les visites des bovins aux points d'eau. En revanche, ils s'orientent préférentiellement vers des sites de pâturage à proximité des abreuvoirs lorsque la température devient supérieure aux températures optimales (Putfarken et al., 2008). Les animaux se sont également rassemblés au niveau des zones d'ombre et des points d'eau dans l'étude de Batista et al. (2019) sur la période où les conditions météorologiques ont excédé la limite supportable. La distribution des animaux et l'utilisation des différents éléments structurants à disposition sont donc influencées par les conditions extérieures, justifiant de s'intéresser aux positions des vaches laitières dans les parcelles pour mieux appréhender les situations d'inconfort.

1.2 Potentiel des accéléromètres et GPS pour remonter des informations sur le comportement et la position des vaches laitières au pâturage

1.2.1 Intérêt des capteurs accéléromètres pour remonter des informations sur le comportement des vaches laitières au pâturage

❖ Diversité de capteurs utilisés dans la littérature

Plusieurs types de capteurs ont été utilisés dans la littérature pour remonter des informations sur le comportement des animaux depuis le début des années 1980. Parmi les principaux capteurs utilisés, on retrouve des capteurs de mesure de résistance électrique, des capteurs acoustiques, des accéléromètres et des capteurs de pression. Les comportements remontés et la position du capteur diffèrent selon les systèmes. Les principaux systèmes retrouvés dans la littérature sont décrits dans le Tableau 8 ci-après.

Tableau 8. Principaux capteurs utilisés dans la littérature depuis 1980 pour remonter des comportements de ruminants automatiquement

Type de capteur	Position capteur	Comportements	Exemple de systèmes	Performance de détection	Référence
Capteurs de mesure de la résistance électrique	Muserolle	Ingestion, rumination et repos	IGER Behaviour recorder	Concordance globale : 91 %	Penning, 1983 Rutter et al., 1997 Rutter, 2000
Microphones (+interrupteur au mercure)	Mâchoire	Comportements unitaires de l'ingestion et de la rumination		Pourcentage de comportements bien classés > 90 %	Nadin et al., 2012 Delagarde et al., 1999 Milone et al., 2012 Navon et al., 2013
Accéléromètre	Cou Nuque Mâchoire Membre Dos	Ingestion, rumination, comportements unitaires, repos, posture.	IceTag3D™	Pourcentage de comportements bien classés* > 90 %	Brown et al., 2013 Delagarde and Lamberton, 2015 Ueda et al., 2011 Dutta et al., 2015 Robert et al., 2009
Capteurs de pression	Mâchoire	Ingestion, rumination, comportements unitaires	RumiWatchSystem	Concordance globale > 90 %	Ruuska et al., 2016 Werner et al., 2018

Note : *les performances dépendent de la position du capteur, des comportements à collecter, des techniques d'analyses utilisées, etc.

- ❖ Sélection des capteurs les plus appropriés : arbitrage entre fonctionnalité, performance et praticité

La liste des différents capteurs énoncée précédemment est non exhaustive mais recense les principaux systèmes présentant suffisamment de documentation scientifique pour mettre en exergue les avantages et limites de chacun. A ce propos, les microphones et capteurs de pression assurent une remontée d'information uniquement sur des comportements mettant en jeu des mouvements de la mâchoire. Ils ne sont donc pas appropriés pour collecter des informations sur l'ensemble des comportements des vaches laitières. A noter que la version la plus récente du RumiWatchSystem remonte des informations sur la plupart des activités des vaches mais nécessite de combiner un capteur de pression et un accéléromètre sur la tête de l'animal ainsi qu'un podomètre sur un membre postérieur. Même si les excellentes performances de ce système témoignent de son potentiel pour la Recherche zootechnique, ces aspects pratiques compromettent nécessairement son transfert vers le terrain (Werner et al., 2018). Les systèmes basés sur des capteurs accéléromètres semblent donc les plus prometteurs pour répondre aux applications envisagées. Ils semblent en effet combiner praticité et performance de détection sur une large gamme de comportements, à condition de mettre en place des techniques d'analyse adaptées.

1.2.2 Intérêt des capteurs GPS pour remonter la position des animaux au pâturage

Plusieurs technologies sont retrouvées dans la littérature pour remonter des informations sur la position des ruminants, comme les systèmes RFID (Williams et al., 2019) ou les systèmes UWB (« Ultra Wideband ») mais les technologies GPS sont certainement les plus adaptées pour les applications souhaitées. Les GPS ont en effet une résolution spatiale suffisante pour une utilisation à l'échelle de la parcelle (erreur en statique sans correction $\approx 3.9 \text{ m} \pm 60.8 \text{ m}$ (moyenne \pm écart-type) ; Ganskopp and Johnson, 2007), remontent la position des animaux en temps réel et de façon régulière.

SYNTHESE

Le comportement des vaches laitières semble constituer un indicateur pertinent pour évaluer l'état de la ressource sur la parcelle ainsi que l'état de santé/confort des animaux, à condition de remonter suffisamment d'information. La position des vaches laitières dans la parcelle mérite d'être collectée pour les mêmes fins. Parmi les principaux capteurs utilisés dans la littérature, il semblerait que les accéléromètres et capteurs GPS soient les plus pertinents pour obtenir des informations sur le comportement et la position de ruminants, respectivement.

2. Méthodes utilisées pour classifier des comportements de ruminants à partir de capteurs accéléromètres embarqués

La revue de Brown et al. (2013) met en exergue la méthodologie la plus fréquemment utilisée pour obtenir des comportements d'animaux à partir de données accéléromètres. Celle-ci s'envisage généralement en quatre étapes, comme illustré dans la Figure 8. La première étape vise à collecter des données brutes à partir d'un accéléromètre embarqué sur l'animal. Les animaux sont également observés en parallèle de façon à coupler le signal accéléromètre enregistré avec les activités observées. La seconde étape consiste à traiter le signal accéléromètre afin d'extraire des variables pertinentes qui seront utilisées à l'étape suivante pour entraîner un algorithme de classification. Enfin, la dernière étape vise à valider le modèle calibré.

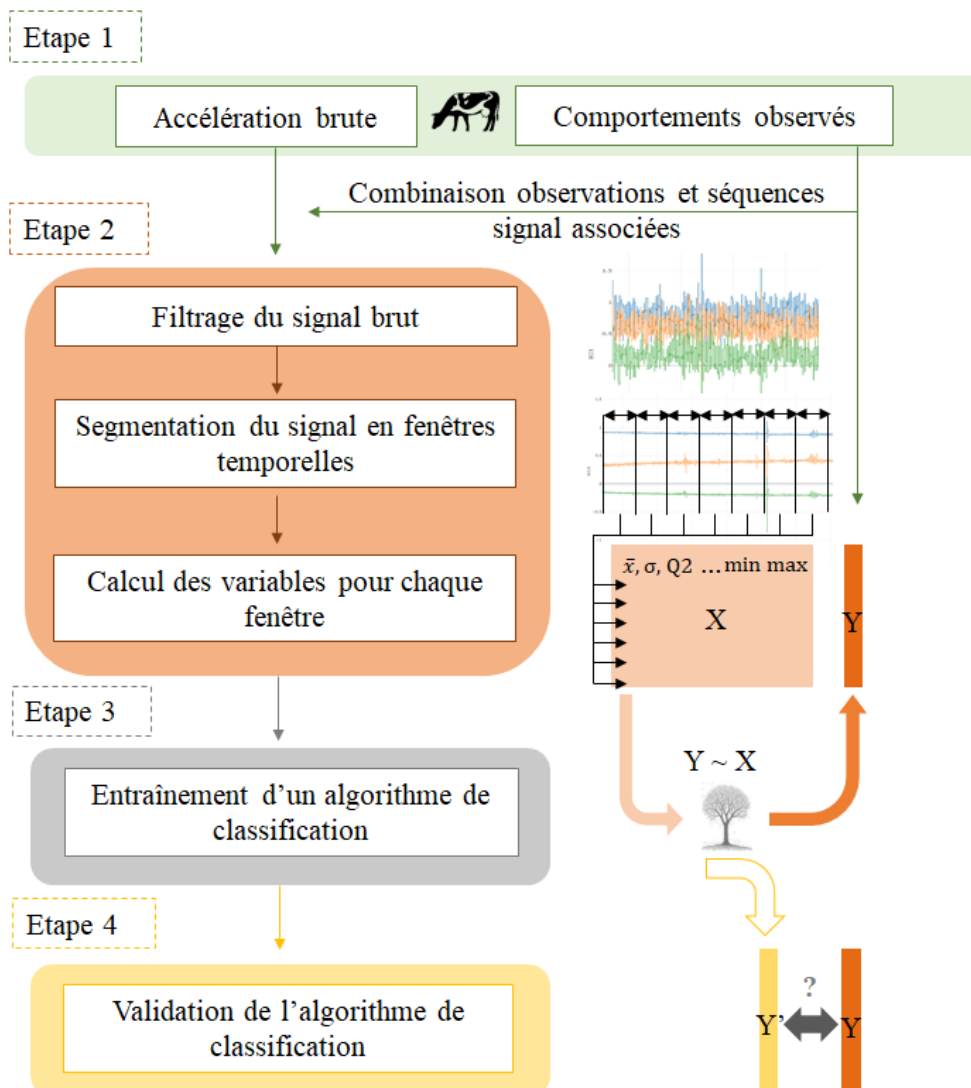


Figure 8. Vue d'ensemble sur la méthodologie pour classifier des comportements de ruminants à partir de données accéléromètres brutes

Cette approche globale est commune aux différentes études mais plusieurs méthodes peuvent néanmoins être mises en œuvre à chaque étape. Il convient alors d'identifier les principales sources de diversité dans les études afin d'orienter les choix qui devront être faits par la suite pour classifier les comportements des vaches laitières au pâturage. Pour cela, 25 études publiées au cours des 10 dernières années ayant pour objectif de classifier des comportements de ruminants (bovins, caprins et ovins) à partir de données accéléromètres brutes ont été prises en compte. Les principales méthodes abordées à chaque étape sont présentées dans les parties suivantes.

2.1 Acquisition des données brutes

Objectif de l'étape : collecter des données accéléromètres à partir de capteurs embarqués, couplées à des observations sur le comportement des animaux

Des variabilités sont observées d'une étude à l'autre dès la première étape. Ces différences reposent autant sur le cadre expérimental mis en œuvre pour collecter des données accéléromètres couplées aux comportements des animaux (espèces étudiées, durée d'expérimentation, position du capteur, etc.) que sur des aspects technologiques (nombre de dimensions de l'accéléromètre, fréquence d'échantillonnage). Les principales différences observées dans les 25 études prises en compte sont synthétisées dans le Tableau 9. Le détail des protocoles utilisés pour chacune des études est proposé en Annexe II.

Tableau 9. Principaux critères de variabilité des protocoles expérimentaux mis en place dans les études considérées

Caractéristiques	Classes*	Références	
Espèces étudiées	Bovins	Andriamandroso et al., 2017 Hamalainen et al., 2011	
	Ovins	Barwick et al., 2018 Giovannetti et al., 2017	
	Caprins	Moreau et al., 2009 Kamminga et al., 2018	
Nombre d'animaux équipés	< 5	Moreau et al., 2009 Giovannetti et al., 2017	
	[5 ; 10[Vázquez Diosdado et al., 2015 Weizheng et al., 2019	
	[10 ; 20[Robert et al., 2009 Andriamandroso et al., 2017	
	≥ 20	Martiskainen et al., 2009 Smith et al., 2016	
Position capteur	Nuque	Nadimi et al., 2008 Arcidiacono et al., 2017	
	Mâchoire	Watanabe et al., 2008 Decandia et al., 2018	
	Cou	Martiskainen et al., 2009 Vázquez Diosdado et al., 2015	
	Dos	Moreau et al., 2009 Lush et al., 2018	
	Oreille	Abell et al., 2017 Barwick et al., 2018	
	Membre	Barwick et al., 2018 Robert et al., 2009	
Durée expérimentation	≤ 1 jour	Watanabe et al., 2008 Mattachini et al., 2016	
]1 jour ; 7 jours]	Vázquez Diosdado et al., 2015 Benaissa et al., 2018	
] 7 jours ; 1 mois]	Robert et al., 2009 Weizheng et al., 2019	
	> 1 mois	Martiskainen et al., 2009 Andriamandroso et al., 2017	
Comportements observés**	Bovins	Ingestion/Rumination	Dutta et al., 2015
			Gonzalez et al., 2015
		Benaissa et al., 2018	
		Weizheng et al., 2019	
	Marche	Dutta et al., 2015	
		Rahman et al., 2018	
	Repos	Martiskainen et al., 2009	
		Robert et al., 2009	
Posture	Dutta et al., 2015		
	Gonzalez et al., 2015		
Hokkanen et al., 2011			
Watanabe et al., 2008			
Abell et al., 2017			
	Robert et al., 2009		

			Vázquez Diosdado et al., 2015
		Evènements	Abell et al., 2017
			Vázquez Diosdado et al., 2015
	Ovins	Ingestion/Rumination	Alvarenga et al., 2016 Giovanetti et al., 2017
		Repos	Giovanetti et al., 2017
		Posture	Alvarenga et al., 2016 Barwick et al., 2018
		Marche/Court	Alvarenga et al., 2016 Lush et al., 2018
		Interaction sociale	Lush et al., 2018
		Evènements	Lush et al., 2018
	Caprins	Ingestion	Moreau et al., 2009
		Repos	Moreau et al., 2009
		Marche	Moreau et al., 2009 Kammaing et al., 2018
		Court/Trotte	Kammaing et al., 2018
		Evènements	Kammaing et al., 2018
Interaction sociale		Kammaing et al., 2018	
Durée d'encodage	< 10 h	Hamalainen et al., 2011 Mattachini et al., 2016	
	[10 h ; 50 h]	Robert et al., 2009 Giovanetti et al., 2017	
	> 50 h	Martiskainen et al., 2009 Kammaing et al., 2018	
Fréquence échantillonnage	< 10 Hz	Moreau et al., 2009 Abell et al., 2017	
	[10 Hz ; 30 Hz]	Martiskainen et al., 2009 Gonzalez et al., 2015	
	> 30 Hz	Vázquez Diosdado et al., 2015 Andriamandroso et al., 2017	
Nombre dimensions accéléromètre	2D	Nadimi et al., 2008	
	3D	Martiskainen et al., 2009 Weizheng et al., 2019	

Note :

* Les classes les plus représentées sur l'ensemble des études sont écrites sur fond bleu.

** Les comportements observés au pâturage sont écrits sur fond vert ; les comportements observés au bâtiment sont écrits sur fond orange.

2.2 Des données accéléromètres brutes au modèle de classification des comportements

2.2.1 Le filtrage du signal brut

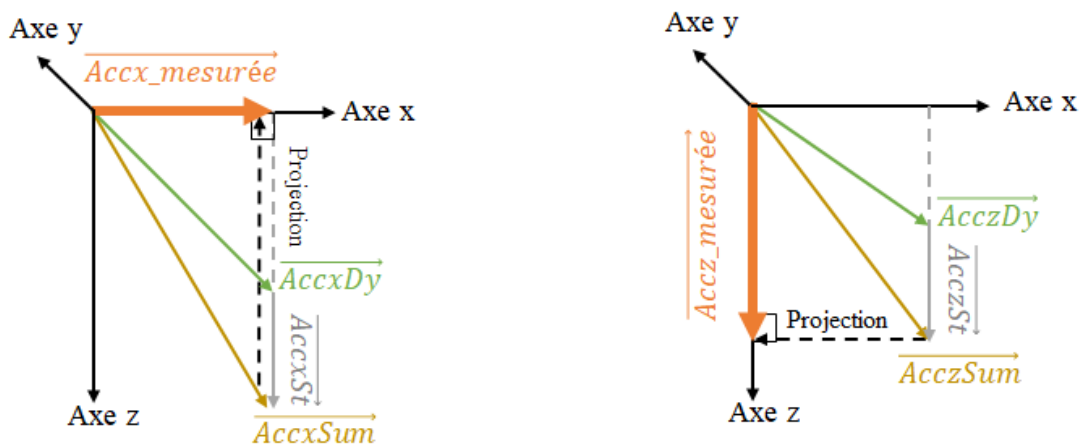
Objectifs de l'étape (Brown et al., 2013) :

- ❖ Isoler les composantes gravité et dynamique
- ❖ Sélectionner des fréquences spécifiques
- ❖ Réduire le niveau de bruit dans le signal

Les principales méthodes de filtrage utilisées dans les études visant à classifier des comportements de ruminants sont expliquées dans cette section et détaillées pour chacune d'elle en Annexe III. Dans cette partie, les différentes méthodes utilisées ont également été comparées aux pratiques mises en œuvre dans des domaines connexes afin de de mettre en exergue d'éventuelles pratiques pertinentes qui n'auraient pas été envisagées par la communauté concernée. En particulier, l'attention a été portée sur des études visant à classifier des comportements d'animaux domestiques et non domestiques ou à reconnaître des activités humaines à partir de données accéléromètres brutes.

❖ Filtrer pour isoler les composantes gravité et dynamique

Dans le contexte étudié, le signal peut d'abord être filtré pour isoler les deux composantes principales du signal. L'accélération brute présente en effet une composante statique (AccSt) liée à la gravité et une composante dynamique (AccDy) liée aux mouvements des animaux. La représentation vectorielle de ces deux composantes est illustrée par la Figure 9 ci-dessous.



Légende :

En supposant que l'accélération est mesurée sur 3 axes et que l'orientation du capteur reste la même au cours du mouvement, on a :

$$\vec{Accx_mesurée} = \vec{AccxDy} + \vec{AccxSt}$$

$$\vec{Accy_mesurée} = \vec{AccyDy} + \vec{AccySt}$$

$$\vec{Accz_mesurée} = \vec{AcczDy} + \vec{AcczSt}$$

- ➔ Accélération mesurée sur l'axe i ($\vec{Acci_mesurée}$)
- ➔ Vecteur accélération gravitationnelle de l'axe i ou accélération statique (\vec{AcciSt})
- ➔ Vecteur accélération issue du mouvement de l'animal sur l'axe i ou accélération dynamique (\vec{AcciDy})
- ➔ $\vec{AcciSum} = \vec{AcciDy} + \vec{AcciSt}$

Figure 9. Représentation vectorielle des composantes statiques et dynamiques de l'accélération mesurée

Des techniques usuelles de traitement du signal permettent de séparer ces deux composantes afin de pouvoir les traiter de façon distincte par la suite :

- L'accélération statique est généralement isolée en calculant une moyenne glissante sur un grand nombre de mesures (Vázquez Diosdado et al., 2015). Elle peut ensuite servir au calcul de nouvelles séries temporelles indicatrices de l'orientation des animaux dans le plan, comme les séries *pitch* et *roll* dans le cas où l'accéléromètre est fixé autour du cou (Dutta et al., 2015).
- L'accélération dynamique du signal peut être obtenue en soustrayant l'accélération statique à l'accélération brute (Lush et al., 2018). L'accélération statique étant continue, elle est nécessairement associée à des fréquences proches de zéro. Elle peut donc aussi être éliminée *via* un filtre passe haut à 0.3 Hz par exemple, comme proposé par Smith et al. (2016). L'accélération dynamique est souvent utilisée pour calculer de nouvelles séries temporelles indicatrices du niveau d'activité de l'animal, comme le vecteur d'accélération dynamique (VeDBA) et l'accélération totale du corps (OBDA), souvent assimilés à l'énergie dépensée par les animaux au cours du mouvement (Benaïssa et al., 2017).

Le calcul des nouvelles séries temporelles à partir des accélérations statiques et dynamiques est détaillé dans la Figure 10.

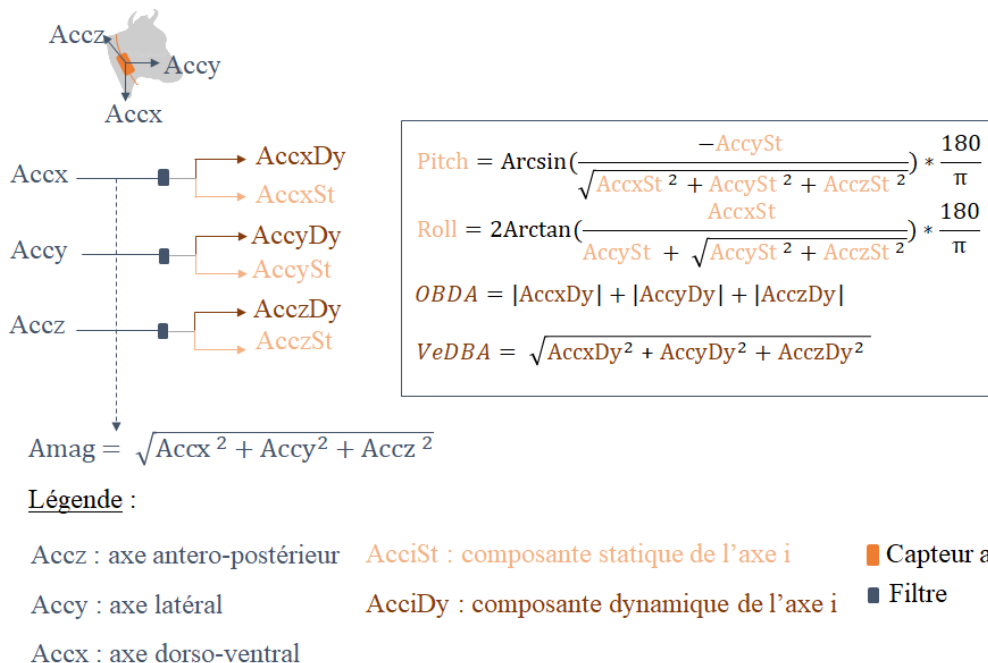


Figure 10. Calcul de nouvelles séries temporelles à partir de l'accélération brute (magnitude notée Amag), statique (*pitch* et *roll*) et dynamique (vecteur d'accélération dynamique notée VeDBA ; accélération totale du corps notée OBDA)

❖ Filtrer pour sélectionner des fréquences particulières

L'accélération brute peut également être filtrée pour extraire des comportements associés à une borne de fréquences particulières. C'est par exemple ce qui est entrepris par Andriamandroso et al. (2017) où les fréquences entre 1 et 2 Hz ont été sélectionnées avec un filtre passe-bande afin d'isoler les mouvements répétitifs de la mâchoire lors des comportements d'ingestion et de rumination.

❖ Filtrer pour réduire le niveau de bruit dans le signal

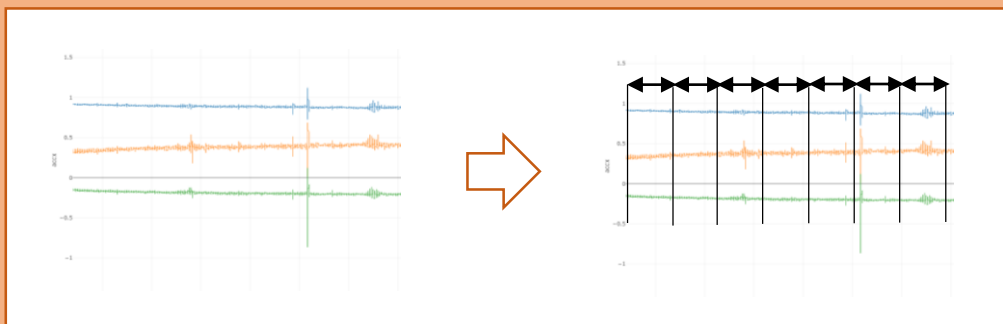
Dans les domaines connexes, le signal est très souvent filtré pour diminuer le niveau de bruit *via* un filtre passe-bas ou un filtre médian par exemple (Sellers and Crompton, 2004; Yang, 2009). En classification des comportements de ruminants, une seule étude s'est attachée à réduire le niveau de bruit par normalisation du signal (Andriamandroso et al., 2017).

Les variables peuvent être extraites directement à partir du signal brut. C'est d'ailleurs le cas de la majeure partie des études considérées (Annexe III). Dans ce cas, la magnitude du signal est généralement calculée à partir des accélérations brutes de chacun des trois axes (Barwick et al., 2018) afin d'obtenir une série temporelle indépendante de l'orientation du capteur (Fida et al., 2015), comme illustré dans la Figure 10.

Finalement, il convient de faire remarquer que l'impact du filtrage et du type de filtre utilisé sur la qualité de la classification des comportements n'a pas été évalué dans cette communauté, contrairement en reconnaissance des activités humaines (Erdaş et al., 2016).

2.2.2 La segmentation du signal

Objectifs de l'étape : Segmenter chacune des séries temporelles en fenêtres pour constituer l'unité statistique du jeu de données

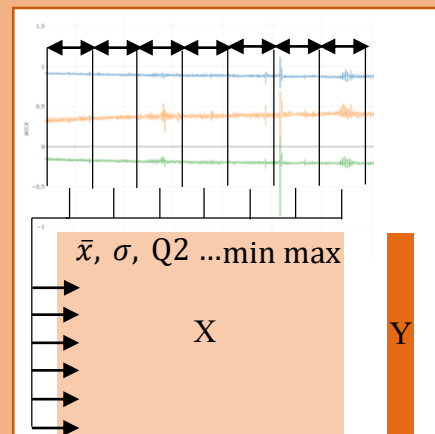


Cette étape vise à segmenter les séries temporelles du signal en tranches appelées fenêtres. Chaque fenêtre constituera l'unité statistique du jeu de données par la suite. La littérature sur la reconnaissance des activités humaines *via* des données accéléromètres met en exergue une

diversité de segmentations possibles (Bersch et al., 2014). Les séries temporelles du signal peuvent être segmentées en fenêtres de taille fixe avec ou sans recouvrement entre fenêtres (Pietka, 1988). Au contraire, le signal peut être segmenté avec des fenêtres dont la taille résulte d'un partitionnement (approche descendante) ou d'une agrégation (approche ascendante) selon un critère donné (Keogh et al., 2001). Bien qu'une diversité de segmentations soit mise en jeu dans les domaines connexes, seules des fenêtres de taille fixe sont utilisées en classification de comportements de ruminants, très majoritairement sans recouvrement (Annexe III). La taille des fenêtres, généralement exprimée en secondes, est en revanche très variable d'une étude à l'autre, allant de quelques secondes (Robert et al., 2009) à plus de 15 minutes (Nadimi et al., 2008). L'effet de la taille de la fenêtre sur la qualité de la classification des comportements par l'algorithme a d'ailleurs été étudié dans plusieurs études (Decandia et al., 2018; Robert et al., 2009; Smith et al., 2016).

2.2.3 Extraction des variables

Objectif de l'étape : Calculer des variables dans chacune des fenêtres qui résument au mieux l'information portée par le signal associé à chacun des comportements à classifier.



Les comportements des animaux se composent d'un enchaînement de mouvements unitaires dont les principales caractéristiques peuvent être extraites à partir du signal accéléromètre. Il convient d'extraire dans chaque fenêtre un ensemble de variables complémentaires qui caractérisent le plus finement possible les activités des ruminants. L'algorithme de classification étant basé sur ces variables, il est en effet primordial qu'elles soient représentatives des comportements à classifier.

Selon la littérature (Brown et al., 2013), l'ensemble des variables calculées sur différentes séries temporelles dans différents domaines peuvent *a priori* apporter trois types d'information sur le comportement de l'animal : le niveau d'activité du mouvement, le type de

mouvement (périodique, aléatoire, fréquences propres etc.) et l'orientation de l'animal dans le plan (Figure 11).

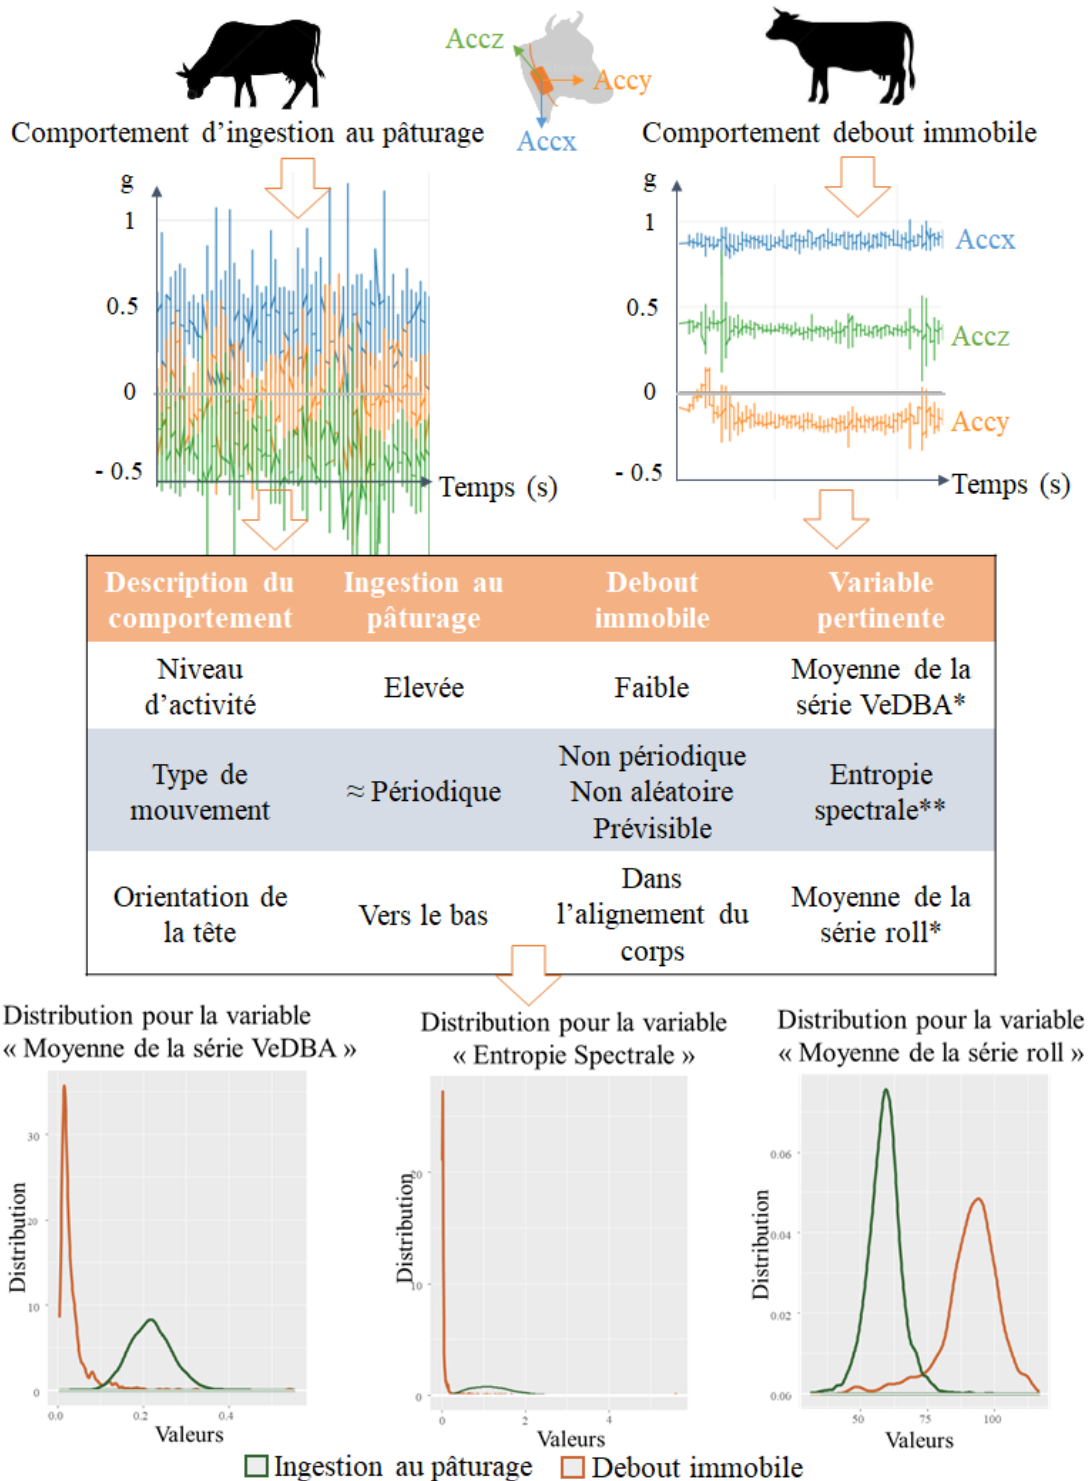


Figure 11. Extraction de variables représentatives du signal associé aux comportements : exemple avec le comportement d'ingestion au pâturage et d'immobilité chez la vache laitière.

Note : * Les formules des séries VeDBA et roll sont fournies dans la Figure 10.

** L'entropie spectrale est calculée dans le domaine fréquentiel et transcrit directement le caractère aléatoire (entropie élevée) ou au contraire prévisible (entropie proche de 0) du mouvement. Sa définition exacte est fournie en Annexe IV.


Dans la communauté concernée, les variables sont majoritairement extraites dans le domaine temporel (Barwick et al., 2018) mais elles peuvent également être obtenues dans le domaine fréquentiel après calcul de la transformée de Fourier (Smith et al., 2016). Les principales variables calculées sur chacune des séries temporelles et leur domaine d'extraction sont résumées dans le Tableau 10. Le détail pour chacune des études considérées est fourni en Annexe III. Les formules des principales variables utilisées dans la communauté sont quant à elles fournies en Annexe IV.

Tableau 10. Principales variables et leur domaine d'extraction calculées dans les études de classification des comportements de ruminants.

Type d'information	Série temporelle	Domaine d'extraction	Variables	Références
Niveau d'activité du mouvement	Amag ; AccxDyn ; AccyDyn ; AcczDyn ; VeDBA ; OBDA	Domaine temporel	Moyenne ; Moyenne cumulée ; Moyenne quadratique ; Quartiles ; Ecart-type ; Variance ; Médiane ; Energie ; SMA	Benaïssa et al., 2017 Kammaing et al., 2018 Lush et al., 2018 Smith et al., 2016 Vázquez Diosdado et al., 2015 Andriamandroso et al., 2017
Type de mouvement	Amag ; Accx ; Accy ; Accz ; AccxDyn ; AccyDyn ; AcczDyn	Domaine temporel	Entropie ; Asymétrie ; Aplatissement ; Corrélation entre les axes ; Variation de mouvement ; Taux de valeurs nulles	Abell et al., 2017 Barwick et al., 2018 Dutta et al., 2015 Hokkanen et al., 2011 Kammaing et al., 2018 Martiskainen et al., 2009
		Domaine fréquentiel	Entropie spectrale, Energie spectrale, Coefficients autorégressifs de la FFT ; DSP maximale et fréquences associées	Kammaing et al., 2018 Lush et al., 2018 Rahman et al., 2018 Weizheng et al., 2019
Orientation de l'animal	Accx ; Accy ; Accz	Domaine temporel	Moyenne	Martiskainen et al., 2009 Moreau et al., 2009 Robert et al., 2009 Dutta et al., 2015 Gonzalez et al., 2015 Alvarenga et al., 2016 Giovanetti et al., 2017 Barwick et al., 2018 Kammaing et al., 2018
	AccxSt ; AccySt ; AcczSt ; <i>pitch</i> ; <i>roll</i>	Domaine temporel	Moyenne ; Ecart-type	Abell et al., 2017 Andriamandroso et al., 2017 Alvarenga et al., 2016 Smith et al., 2016 Lush et al., 2018

2.3 De la matrice des variables à la classification des comportements des ruminants

Objectif de l'étape : Calibrer un modèle de classification des comportements des ruminants à partir des variables calculées à l'étape précédente pour chacune des fenêtres.



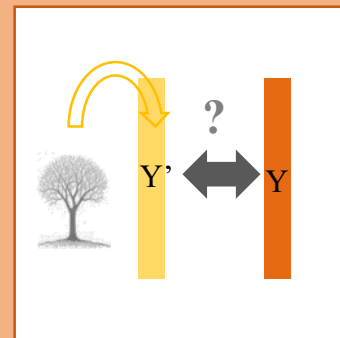
Cette étape vise à établir un modèle qui discrimine au mieux les comportements observés à partir des variables extraites du signal accéléromètre. Les modèles établis dans la communauté concernée sont principalement établis à partir de méthodes de classification supervisée de *machine learning* (ML) (Barwick et al., 2018; Robert et al., 2009; Smith et al., 2016). Des méthodes ensemblistes représentées par les techniques de *bagging* et de *boosting* sont également mises en œuvre dans plusieurs études (Dutta et al., 2015; Lush et al., 2018). Des méthodes de *deep learning* (Kamminga et al., 2018) ainsi que des modèles probabilistes (Vázquez Diosdado et al., 2015) sont également retrouvés de façon marginale. Enfin, des méthodes de seuillage visant à fixer arbitrairement les seuils à partir de la distribution des variables sont aussi envisagées dans la littérature (Andriamandroso et al., 2017; Arcidiacono et al., 2017). Les principaux algorithmes mis en jeu dans les 25 études prises en compte sont synthétisés dans le Tableau 11 ci-après. Le détail pour chacune d'elle est fourni en Annexe III.

Tableau 11. Principales méthodes et algorithmes mis en jeu pour classifier les comportements des ruminants à partir de variables issues du signal accéléromètre.

Type de méthodes	Algorithmes		Références
Méthodes de classification supervisée de <i>machine learning</i>	Arbre de décision		Robert et al., 2009 Alvarenga et al., 2016
	Analyse discriminante linéaire ou quadratique		Giovanetti et al., 2017 Barwick et al., 2018
	Régression logistique		Smith et al., 2016
	Classifieur bayésien naïf		Smith et al., 2016 Benaissa et al., 2017
	Support Vector Machine		Martiskainen et al., 2009 Benaissa et al., 2018
	K plus proches voisins		Kammaing et al., 2018 Weizheng et al., 2019
Méthodes ensemblistes		Classifieur faible	
	<i>Bagging</i>	Analyse linéaire discriminante	Dutta et al., 2015
		K plus proches voisins	Dutta et al., 2015
		Arbre de décision	Lush et al., 2018 Dutta et al., 2015
	<i>Boosting</i>	Analyse linéaire discriminante	Dutta et al., 2015
		K plus proches voisins	
Arbre de décision			
Méthode de <i>deep learning</i>	Réseaux de neurones		Kammaing et al., 2018 Weizheng et al., 2019
Méthodes probabilistes	Modèle de Markov Caché		Vázquez Diosdado et al., 2015
Méthodes de seuillage			Andriamandroso et al., 2017 Arcidiacono et al., 2017

2.4 Validation du modèle de classification

Objectif de l'étape : Valider le modèle de classification des comportements des ruminants, *i.e.*, estimer les performances du modèle en vue d'évaluer sa fiabilité en élevage par la suite.



L'étape de validation de l'algorithme s'effectue classiquement en deux étapes (Hastie et al., 2011). Comme illustré dans la Figure 12, cette étape consiste (1) à utiliser le modèle établi précédemment pour prédire les comportements associés à des fenêtres qui n'ont pas été utilisées lors de la calibration du modèle puis (2) à comparer les comportements prédits par le modèle aux comportements observés sur le terrain via une matrice de confusion. Cette matrice sert alors de support au calcul de métriques de performance. Ces métriques relatent à la fois les performances globales du modèle mais également les performances de prédiction associées à chacun des comportements.

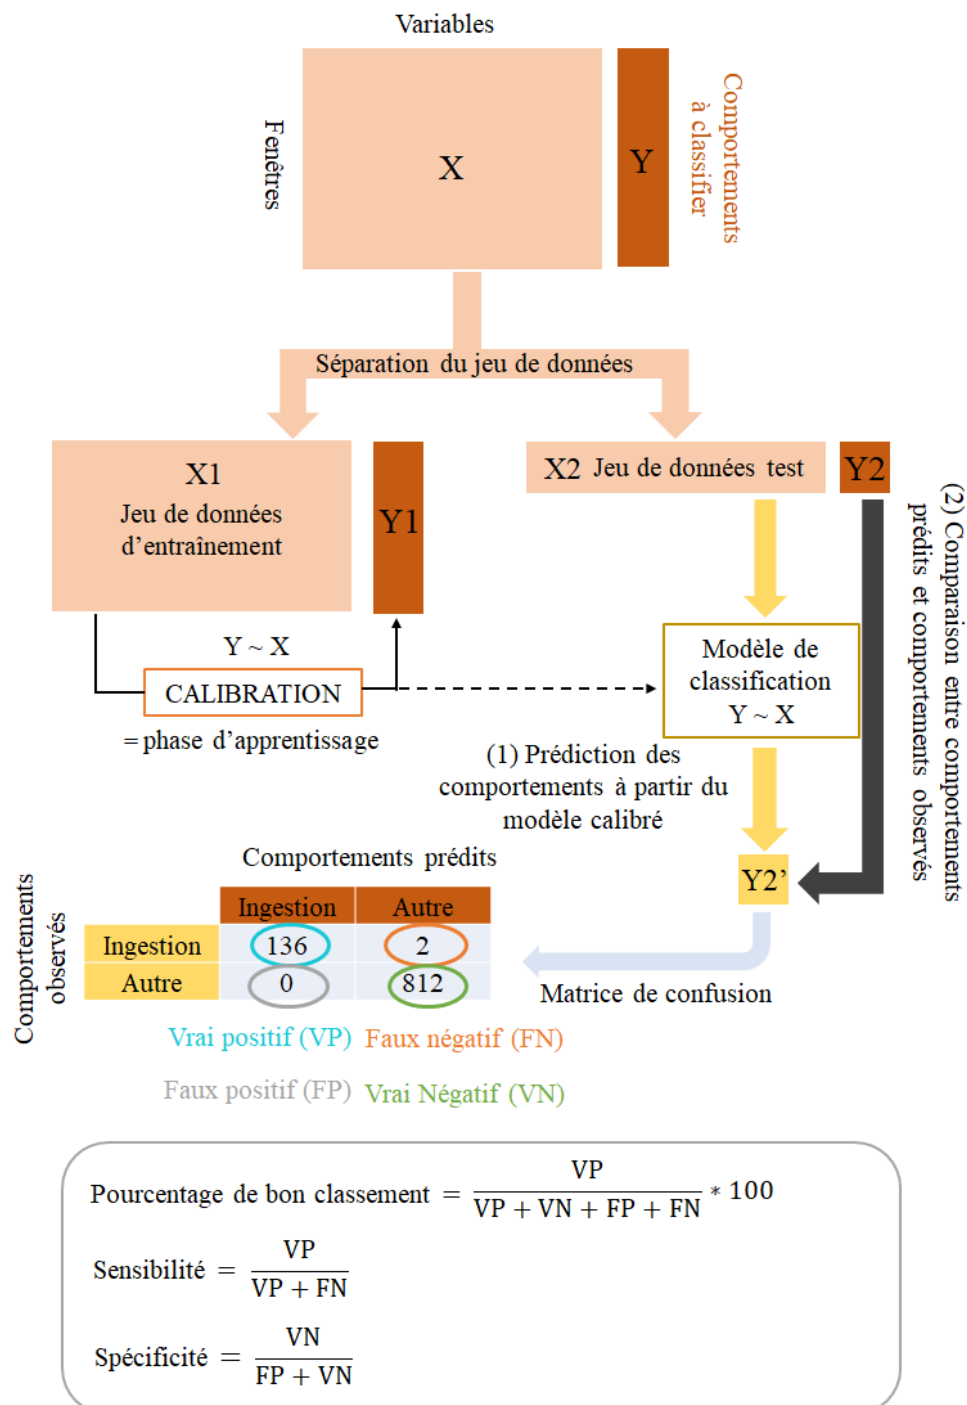


Figure 12. Principe de l'étape de validation d'un modèle de classification supervisée

Comme illustré dans la Figure 12, l'étape de validation nécessite d'avoir scindé le jeu de données au préalable de façon à entraîner le modèle uniquement sur une partie (jeu de données d'entraînement) et à le valider sur la partie restante (jeu de données test). A ce propos, la différence majeure identifiée dans les études considérées repose sur le critère utilisé pour scinder le jeu de données. La séparation de celui-ci peut ainsi être réalisée :

- (1) **Sans critère particulier.** La séparation est alors aléatoire et des fenêtres de signal associées à un même animal sur une même période d'observation se retrouvent à la fois dans le jeu de données d'entraînement et dans celui de test (Barwick et al., 2018).
- (2) **Sur la base de la période à laquelle les observations ont été faites.** Dans le cas où les animaux ont été observés en plusieurs temps, le modèle peut être calibré avec les observations d'un ou plusieurs jours et validé avec les observations des jours restants (Nadimi et al., 2008).
- (3) **Sur la base de l'individu observé.** La séparation est alors réalisée de façon à ce que les fenêtres issues d'un même animal soient retrouvées dans le jeu de données d'entraînement ou de test exclusivement (Smith et al., 2016).

Quel que soit le critère de séparation choisi, le modèle peut être validé sur un jeu de données indépendant (Martiskainen et al., 2009) ou *via* des techniques de validation croisée (Hastie et al., 2011), régulièrement mises en œuvre dans la communauté (Benaissa et al., 2018; Smith et al., 2016). Les métriques les plus couramment rencontrées pour évaluer les performances du modèle sont le pourcentage de bon classement, la sensibilité et la spécificité dont les définitions sont fournies dans la Figure 12, mais le Kappa de Cohen (Cohen, 1960) ou encore le Fscore sont également utilisées (Martiskainen et al., 2009; Smith et al., 2016). Les critères de séparation du jeu de données, la technique de validation et les métriques mis en œuvre dans chacune des 25 études respectives sont fournis en Annexe III.

SYNTHESE

Un cadre méthodologique en quatre étapes commun à l'ensemble des études visant à classifier le comportement des ruminants à partir d'un capteur accéléromètre a pu être identifié. Une diversité de méthodes a néanmoins été mise en œuvre à chacune des étapes, qu'ils s'agissent des protocoles utilisés, des techniques d'analyses ou encore des méthodes de validation. Une revue de la littérature sur les domaines connexes, notamment en reconnaissances des activités humaines *via* un accéléromètre, a permis d'identifier un ensemble de méthodes qui n'ont pas été envisagées en classification des comportements de ruminants, notamment pour la partie traitement des données accéléromètres brutes (étape 2).

3. Evaluation des méthodes mises en œuvre pour classifier les comportements des ruminants

3.1 Identification des différents aspects méthodologiques conduisant aux meilleures performances de classification

Cette partie a pour objectif d'identifier les différents aspects méthodologiques qui conduisent à de très bonnes performances de classification des comportements de ruminants. L'attention a été portée à la fois sur le volet expérimental (acquisition de données) et sur le volet développement (traitement du signal brut et classification des comportements). A ce propos, la diversité des protocoles, des techniques d'analyse et de validation des algorithmes rend la comparaison des performances d'une étude à l'autre difficile. Aussi, il est préférable de comparer les différents aspects méthodologiques testés au sein d'une même étude afin de mettre en exergue les techniques favorables à de bonnes performances, toute chose égale par ailleurs. Les performances obtenues dans chacune des études considérées sont détaillées en Annexe V.

3.1.1 Acquisition des données

❖ Fréquence d'échantillonnage

La fréquence d'échantillonnage de l'accéléromètre conditionne directement les performances de l'algorithme. Benaïssa et al. (2018) montrent ainsi une diminution progressive du pourcentage de fenêtres bien classées en sous-échantillonnant le signal de 10 Hz (93 %) à 0.5 Hz (86 %). L'intérêt d'un échantillonnage supérieur à 10 Hz n'a pas été évalué dans la littérature mais il semble pertinent de considérer un échantillonnage supérieur à 20 Hz dans le cas où des comportements de bovins sont à classifier. Hamalainen et al. (2011) expliquent en effet que les fréquences des mouvements générés par les bovins sont *a priori* inférieures à 10 Hz. Une fréquence d'échantillonnage de 20 Hz satisfait ainsi le théorème de Shannon et devrait donc être suffisante pour remonter toute l'information.

❖ Position du capteur

L'effet de la position du capteur sur la qualité de la classification des comportements a été étudié dans plusieurs études. La position du capteur sur l'animal conditionne effectivement la classification de chacun des comportements au cas par cas. Comme illustré dans le Tableau 12, des capteurs placés au niveau du cou sont à privilégier pour classifier les comportements alimentaires tandis que des capteurs placés aux membres favoriseront la discrimination entre

les différentes postures. A ce propos, placer plusieurs accéléromètres à des positions différentes sur l'animal est certainement un moyen d'optimiser la classification d'une large gamme de comportements (Benaissa et al., 2017) mais cette approche semble difficilement transférable sur le terrain, pour des raisons évidentes de coût et de praticité.

Tableau 12. Performances de classification du comportement d'ingestion et de la position couchée avec un capteur au collier et au membre.

Position capteur		Collier		Membre		Référence
Comportement		Ingestion	Couché	Ingestion	Couché	
Métriques de performance	Sensibilité (%)	92	61	85	100	Barwick et al., 2018
	Spécificité (%)	95	99	88	100	
	% bien classés	93	95	86	100	
	Sensibilité (%)	96	83	86	99	Benaissa et al., 2017
	Précision(%)	92	97	81	98	

3.1.2 Développement

❖ Taille de la fenêtre

Toutes les études ayant testé différentes tailles de fenêtres confirment l'effet de ce paramètre sur la qualité de la classification des comportements de ruminants. Il est cependant compliqué d'en extraire des recommandations étant donné la divergence des résultats obtenus. Comme illustré dans le Tableau 13, certaines études ont obtenu de meilleurs résultats avec les fenêtres les plus courtes (Robert et al., 2009), les plus longues (Vázquez Diosdado et al., 2015) ou avec les tailles intermédiaires (Alvarenga et al., 2016).

Ce manque de consensus met en exergue les interactions existant entre les différents aspects techniques et méthodologiques mobilisés. La taille des fenêtres conditionne par exemple le nombre d'échantillons de signal utilisés pour calculer les variables mais celui-ci dépend également de la fréquence d'échantillonnage. Une même taille de fenêtre sera associée à un nombre d'échantillons différent selon la fréquence d'échantillonnage choisie ce qui influencera nécessairement les résultats obtenus. De plus, la calibration des modèles de classification implique l'exclusion de fenêtres de signal associées à plusieurs comportements. Comme expliqué par Andriamandroso et al. (2017), plus la taille de fenêtre sera longue, plus il y aura de fenêtres hétérogènes à éliminer et donc moins il y aura de fenêtres à disposition pour entraîner les modèles. Des fenêtres longues seront donc plus ou moins limitantes selon la taille du jeu de données initial. Enfin, Lush et al. (2018) expliquent que la taille de la fenêtre

doit être suffisamment longue pour remonter une information représentative du comportement à classifier. Son effet sera donc certainement différent selon les comportements considérés.

Tableau 13. Divergence des résultats obtenus pour l'effet de la fenêtre sur la classification des comportements des ruminants

Meilleures performances	Tailles de fenêtres testées (s)	Références
Fenêtres les plus courtes	3 ; 5 ; 10	Robert et al., 2009
	3 ; 5 ; 10	Lush et al., 2018
Fenêtres intermédiaires	3 ; 5 ; 10	Alvarenga et al., 2016
	5 ; 10 ; 30 ; 60 ; 120 ; 180 ; 300	Decandia et al., 2018
Fenêtres les plus longues	60 ; 300 ; 600	Vázquez Diosdado et al., 2015
	1.5 ; 2.5 ; 5 ; 7.5 ; 10 ; 15 ; 20 ; 25 ; 30	Smith et al., 2016

Note : Les fenêtres pour lesquelles les meilleures performances ont été obtenues sont écrites en orange et en gras

❖ Variables extraites

Les études rapportant l'importance relative des variables utilisées par les modèles de classification montrent qu'il y a un intérêt majeur à extraire des variables complémentaires. Qu'ils s'agissent d'analyses discriminantes linéaires (Giovanetti et al., 2017), quadratiques (Barwick et al., 2018) ou encore de forêts aléatoires (Lush et al., 2018; Smith et al., 2016), l'importance relative des variables fait toujours ressortir à la fois des indicateurs de la dynamique du mouvement, de l'orientation de l'animal dans l'espace et du type de mouvement. Selon les comportements à discriminer deux à deux, les variables utilisées prioritairement par les modèles sont en effet différentes. Pour un accéléromètre fixé sur un collier, la moyenne de l'accélération sur l'axe vertical assure par exemple une discrimination forte entre les comportements d'ingestion d'une part et les comportements de rumination et de repos d'autre part (Giovanetti et al., 2017). Ce résultat s'explique par le port de tête différent entre ces comportements qui génère des moyennes d'accélération statique différentes sur cet axe. De la même façon, les caractéristiques du spectre (barycentre, dispersion, aplatissement) ainsi que le premier coefficient de la transformée de Fourier ont une importance relative forte dans la discrimination du comportement de rumination, en lien certainement avec le caractère périodique de ce comportement (Smith et al., 2016). A ce propos, ces résultats remettent en question l'optimalité des performances obtenues lorsque la classification des différents comportements ne repose que sur un seul type de variable (moyenne de l'OBDA ; Benaissa et al., 2018).

❖ Méthode de classification

Les études mettant en jeu plusieurs classifieurs mettent en exergue les très bonnes performances des méthodes de classification supervisée de ML. Les performances des algorithmes de k plus proches voisins (kNN) et de *Support Vector Machine* (SVM) sont par exemple supérieures à celles obtenues avec un réseau de neurones (respectivement : 94.5 %, 93.2 % et 88 % de bon classement ; Weizheng et al., 2019). Les modèles basés sur des algorithmes de ML semblent également plus performants que ceux basés sur des modèles probabilistes (SVM : 87.5 % de bien classés ; modèle de Markov Caché (HMM) : 81.1 % de bien classés ; Vázquez Diosdado et al., 2015). Parmi les algorithmes de ML testés, il convient de préciser les très bonnes performances obtenues systématiquement avec le classifieur SVM (Benaïssa et al., 2018; Smith et al., 2016; Vázquez Diosdado et al., 2015; Weizheng et al., 2019). Les remarquables performances obtenues avec les méthodes ensemblistes de ML méritent enfin d'être soulignées. C'est notamment le cas de l'algorithme de forêt aléatoire (RF) (Abell et al., 2017; Smith et al., 2016) dont les performances sont parfois supérieures à celles de méthodes complexes comme les systèmes d'inférence floue basés sur un réseau de neurones adaptatif (Dutta et al., 2015).

3.2 Limite des méthodologies existantes

A cette étape, deux limites majeures compromettent le développement d'un outil d'aide à la gestion des systèmes pâturant : les performances médiocres des modèles de classification lorsqu'un large spectre de comportements est considéré et la validité des modèles à l'échelle de la période d'observation et de l'individu.

❖ Difficulté de classifier un large spectre de comportements

Comme expliqué précédemment, il est primordial de remonter des informations sur une large gamme de comportements des vaches laitières pour envisager de développer par la suite des modèles de détection d'évènements basés sur ces comportements. A ce propos, Rushen et al. (2012) expliquent qu'une des limites majeures au développement de ces outils repose sur le nombre limité de comportements qui sont classifiés de manière fiable. En effet, des performances satisfaisantes sont obtenues lorsque les études s'attachent à classifier deux ou trois comportements au maximum (Arcidiacono et al., 2017; Benaïssa et al., 2017; Giovanetti et al., 2017). De très bonnes performances ont notamment été obtenues avec un accéléromètre au niveau de la mâchoire lorsque les comportements à classifier se limitent à l'ingestion et à la rumination, avec un pourcentage de fenêtres bien classées supérieur à 90 % pour chacune de

ces deux classes (Andriamandroso et al., 2017; Decandia et al., 2018). Les postures « debout » et « couché » sont également très bien discriminées avec un accéléromètre fixé à un membre (debout : 98 % de bien classés ; couché : 99.2 % de bon classement ; Robert et al., 2009). Néanmoins, les excellentes performances obtenues dans cette dernière étude se dégradent lorsque le comportement de marche est pris en compte, affichant un pourcentage de fenêtres bien classées de 67.8 % uniquement. Le problème est similaire avec un capteur fixé au cou puisque la qualité de la prédiction est satisfaisante tant que les comportements à classer se limitent à l'ingestion, la rumination et le repos, affichant des pourcentages de bon classement, sensibilités et spécificités supérieurs à 90 % pour chacun de ces comportements (Dutta et al., 2015). Les performances deviennent néanmoins médiocres lorsque les postures « couché » et « debout » sont prises en compte dans la classification (Martiskainen et al., 2009). A ce propos, Hamäläinen et al. (2011) expliquent qu'il est impossible de discriminer ces deux postures avec un accéléromètre au collier, la position de la tête et le niveau d'activité étant similaire, et qu'il peut être pertinent à ce propos d'utiliser un algorithme de HMM pour prédire la posture de l'animal en tenant compte de la posture de l'état précédent.

❖ Validité des modèles développés

Selon Rahman et al. (2018), les techniques de validation basées sur des jeux de données d'entraînement et de test comprenant des fenêtres issues des mêmes animaux observés aux mêmes périodes ne sont pas adaptées pour évaluer les modèles (Dutta et al., 2015; Lush et al., 2018). En effet, même si ceci n'a pas été exploré dans la littérature, il est probable que les *patterns* générés dans le signal accéléromètre par un même animal soient différents selon le moment où les comportements sont exprimés (variabilité intra-individuelle). Dans ce cas, une évaluation des modèles avec des fenêtres obtenues sur les mêmes périodes d'observation que celles ayant servi à l'entraînement conduit certainement à des performances optimistes et non représentatives de celles qui seront obtenues sur le terrain. De la même manière, plusieurs auteurs constatent une variabilité importante entre les *patterns* générés pour un même comportement d'une vache à l'autre (variabilité inter-individuelle ; Arcidiacono et al., 2017). Rahman et al. (2018) relatent ainsi des performances dégradées lorsque le modèle est validé sur un individu n'ayant pas été inclus dans le jeu de données d'entraînement (Fscore : 0.64), comparativement à une validation croisée classique (Fscore : 0.93). Les modèles doivent donc rester valides quelle que soit la période où les données sont collectées (échelle de la période) et quelle que soit la vache laitière équipée (échelle de l'individu).

SYNTHESE ET PERSPECTIVES

Parmi les méthodes envisagées en classification des comportements de ruminants, il semblerait que certaines soient à privilégier par rapport à d'autres. En terme de protocole, la position du capteur et la fréquence d'échantillonnage doivent être dûment réfléchis en fonction des objectifs de l'étude. En terme de traitement, la taille de la fenêtre pour la segmentation influence les performances de classification et reste dans tous les cas étude-dépendante. Parmi les méthodes de classification testées, les méthodes de *machine learning*, particulièrement le classifieur SVM et les méthodes ensemblistes, sont à prioriser. Il convient également de rappeler qu'un ensemble de méthodes de traitement des données accéléromètres brutes, non explorées dans la communauté concernée, sont couramment utilisées dans des domaines connexes. Une combinaison pertinente de ces éléments mérite donc d'être explorée en vue de répondre aux deux freins majeurs au développement de ces outils, à savoir (1) le faible nombre de comportements pouvant être prédits de manière fiable et (2) la validité des modèles à l'échelle de la période et de l'individu.

Références

- Abell, K.M., Theurer, M.E., Larson, R.L., White, B.J., Hardin, D.K., Randle, R.F., 2017. Predicting bull behavior events in a multiple-sire pasture with video analysis, accelerometers, and classification algorithms. *Comput. Electron. Agric.* 136, 221–227. <https://doi.org/10.1016/j.compag.2017.01.030>
- Agabriel, J., Disenhaus, C., Renand, G., Zundel, E., Seegers, H., Faverdin, P., 2011. Elevage bovin et Environnement Quelles solutions techniques ou organisationnelles envisagées par l'INRA ? *Innov. Agron.* 12, 135–156.
- Alexandratos, N., 2012. World Agriculture towards 2030/2050: the 2012 revision 154.
- Allain, C., Thomas, G., Chanvallon, A., 2013. Surveillance automatisée des vêlages en élevage bovins laitiers.
- Allain, C., Thomas, G., Chanvallon, A., 2012. Détection automatisée des chaleurs en élevage de bovins laitiers : quel outil choisir ?
- Almeida, P.E., Weber, P.S.D., Burton, J.L., Zanella, A.J., 2008. Depressed DHEA and increased sickness response behaviors in lame dairy cows with inflammatory foot lesions. *Domest. Anim. Endocrinol.* 34, 89–99. <https://doi.org/10.1016/j.domaniend.2006.11.006>
- Alvarenga, F.A.P., Borges, I., Palkovič, L., Rodina, J., Oddy, V.H., Dobos, R.C., 2016. Using a three-axis accelerometer to identify and classify sheep behaviour at pasture. *Appl. Anim. Behav. Sci.* 181, 91–99. <https://doi.org/10.1016/j.applanim.2016.05.026>
- Andriamandroso, A.L.H., 2017. Cattle grazing dynamics under contrasted pasture characteristics at temporal and spatial scales (Sciences agronomiques et ingénierie biologique). Université de Liège, Gembloux Agro-Bio Tech, Liège, Belgique.
- Andriamandroso, A.L.H., Lebeau, F., Beckers, Y., Froidmont, E., Dufrasne, I., Heinesch, B., Dumortier, P., Blanchy, G., Blaise, Y., Bindelle, J., 2017. Development of an open-source algorithm based on inertial measurement units (IMU) of a smartphone to detect cattle grass intake and ruminating behaviors 40.
- Arcidiacono, C., Porto, S.M.C., Mancino, M., Cascone, G., 2017. Development of a threshold-based classifier for real-time recognition of cow feeding and standing behavioural activities from accelerometer data. *Comput. Electron. Agric.* 134, 124–134. <https://doi.org/10.1016/j.compag.2017.01.021>
- Barwick, J., Lamb, D.W., Dobos, R., Welch, M., Trotter, M., 2018. Categorising sheep activity using a tri-axial accelerometer. *Comput. Electron. Agric.* 145, 289–297. <https://doi.org/10.1016/j.compag.2018.01.007>
- Batista, P.H.D., Almeida, G.L.P.D., Sarmento, R.M., Pandorfi, H., Melo, A.A.S.D., Rolim, M.M., Medeiros, V.W.C.D., Gonçalves, G.E., 2019. Monitoring the bovine activity in grazing by an electronic sensing device based on GPS. *Rev. Ciênc. Agrár.* vol. 42 n.º 2 (2019)-. <https://doi.org/10.19084/rca.17264>
- Bellon Maurel, V., Huyghe, C., 2017. Putting agricultural equipment and digital technologies at the cutting edge of agroecology 7.
- Benaissa, S., Tuytens, F.A.M., Plets, D., Cattrysse, H., Martens, L., Vandaele, L., Joseph, W., Sonck, B., 2018. Classification of ingestive-related cow behaviours using RumiWatch halter and neck-mounted accelerometers. *Appl. Anim. Behav. Sci.* <https://doi.org/10.1016/j.applanim.2018.12.003>
- Benaissa, S., Tuytens, F.A.M., Plets, D., de Pessemier, T., Trogh, J., Tanghe, E., Martens, L., Vandaele, L., Van Nuffel, A., Joseph, W., Sonck, B., 2017. On the use of on-cow accelerometers for the classification of behaviours in dairy barns. *Res. Vet. Sci.* <https://doi.org/10.1016/j.rvsc.2017.10.005>

- Béranger, C., Lacombe, P., 2014. La recherche agronomique et la révolution agricole de la seconde moitié du XXe siècle : l'exemple de la prairie. *Histoire de la recherche contemporaine*. Rev. Com. Pour L'histoire CNRS 167-179.
- Béranger, C., Liénard, G., 2006. La Révolution fourragère, 50 ans après. *La Révolution fourragère et les éleveurs*. Fourrages 437-449.
- Béraud, E., Bouhaddi, F., 1996. 25 ans de statistique agricole annuelle – rétrospective 1970 – 1994. *Agreste- Stat. Agric.-Données Chiffrées*.
- Berckmans, D., 2014. Precision livestock farming technologies for welfare management in intensive livestock systems. *Rev. Sci. Tech. OIE* 33, 189–196.
- Bersch, S., Azzi, D., Khusainov, R., Achumba, I., Ries, J., 2014. Sensor Data Acquisition and Processing Parameters for Human Activity Classification. *Sensors* 14, 4239–4270. <https://doi.org/10.3390/s140304239>
- Blackie, N., Bleach, E., Amory, J., Scaife, J., 2011. Impact of lameness on gait characteristics and lying behaviour of zero grazed dairy cattle in early lactation. *Appl. Anim. Behav. Sci.* 129, 67–73. <https://doi.org/10.1016/j.applanim.2010.10.006>
- Borchers, M.R., Chang, Y.M., Tsai, I.C., Wadsworth, B.A., Bewley, J.M., 2016. A validation of technologies monitoring dairy cow feeding, ruminating, and lying behaviors. *J. Dairy Sci.* 99, 7458–7466. <https://doi.org/10.3168/jds.2015-10843>
- Bramley, R.G.V., 2009. Lessons from nearly 20 years of Precision Agriculture research, development, and adoption as a guide to its appropriate application. *Crop Pasture Sci.* 60, 197. <https://doi.org/10.1071/CP08304>
- Bravo, A. (Ed.), 2009. *La société et l'économie à l'aune de la révolution numérique: enjeux et perspectives des prochaines décennies ; (2015 - 2025) ; rapport de la Commission, Rapports et documents / Centre d'Analyse Stratégique*. Documentation Française, Paris.
- Brose, P.W., 1990. Animal training and restraining system. 4,898,120.
- Brown, D.D., Kays, R., Wikelski, M., Wilson, R., Klimley, A.P., 2013. Observing the unwatchable through acceleration logging of animal behavior. *Anim. Biotelemetry* 16p.
- Cardoso, C.S., Hötzel, M.J., Weary, D.M., Robbins, J.A., von Keyserlingk, M.A.G., 2016. Imagining the ideal dairy farm. *J. Dairy Sci.* 99, 1663–1671. <https://doi.org/10.3168/jds.2015-9925>
- Carpentier, B., Cabon, G., 2011. Le maïs fourrage : élaboration du rendement et de la qualité, récolte et conservation. *Fourrages* 11–23.
- Chanvallon, A., Gatien, J., Lamy, J.M., Philipot, J.M., Girardot, J., Davière, J.B., Ribaud, D., Salvetti, P., 2012a. Evaluation automatisée des chaleurs par différents appareils chez la vache laitière. Presented at the Rencontre Recherche Ruminants.
- Chanvallon, A., Leblay, A., Girardot, J., Davière, J.B., Ribaud, D., Allain, C., Lamy, J.M., 2012b. Surveillance automatisée des vêlages chez la vache laitière.
- Chauvin, A., 2009. Le risque parasitaire au pâturage et sa maîtrise 255–264.
- Chauvin, A., Vermesse, R., Lardoux, S., Masson, M., 2008. Parasit'Info : un système expert d'aide à la gestion du risque d'helminthoses en élevage bovin. Presented at the Rencontre Recherche Ruminants.
- Chénaïs, F., Seuret, J.M., Brunschwig, P., Fiorelli, J.L., 2001. Pour un rôle croissant du pâturage dans les systèmes bovins laitiers 17.
- Chilliard, Y., Bauchart, D., Lessire, M., Schmidely, P., Mourot, J., Champanelle, S.-G., 2008. Qualité des produits : modulation par l'alimentation des animaux de la composition en acides gras du lait et de la viande 12.
- Claveirole, C., 2016. *La transition agroécologique : défis et enjeux* (No. CESL1100013X). Conseil économique, social et environnemental.
- Cohen, J., 1960. A Coefficient of Agreement for Nominal Scales. *Educ. Psychol. Meas.* 20, 37–46. <https://doi.org/10.1177/001316446002000104>

- Coulon, J.-B., Delacroix-Buchet, A., Martin, B., Pirisi, A., 2005. Facteurs de production et qualité sensorielle des fromages. *Prod. Anim.* 1, 49–62.
- Couvreur, S., Delaby, L., Doligez, E., Mahmoudi, P., Marnay, L., Michaud, A., Navelet, C., Paulin, S., Plantureux, S., Puthod, R., 2018. Les prairies au service de l'élevage. Comprendre, gérer et valoriser les prairies., Educagri éditions. ed. Dijon.
- de Schutter, O., 2010. Rapport: agroécologie et droit à l'alimentation (No. GE.10-17850). Organisation des Nations Unies, Genève.
- Decandia, M., Giovanetti, V., Molle, G., Acciario, M., Mameli, M., Cabiddu, A., Cossu, R., Serra, M.G., Manca, C., Rassu, S.P.G., Dimauro, C., 2018. The effect of different time epoch settings on the classification of sheep behaviour using tri-axial accelerometry. *Comput. Electron. Agric.* 154, 112–119. <https://doi.org/10.1016/j.compag.2018.09.002>
- Delagarde, R., Caudal, J.-P., Peyraud, J.-L., 1999. Development of an automatic bitemeter for grazing cattle. *Ann. Zootech.* 48, 329–339. <https://doi.org/10.1051/animres:19990501>
- Delagarde, R., Peyraud, J.-L., Wade, M.H., 2010. Daily pattern of feeding activities of dairy cows in a 8-d rotational grazing system. Presented at the 23rd General Meeting of the European Grassland Federation, Kiel, Germany, pp. 931–933.
- Delanoue, E., Roguet, C., 2015. Acceptabilité sociale de l'élevage en France : recensement et analyse des principales controverses à partir des regards croisés de différents acteurs 12.
- Desriers, M., 2007. L'agriculture française depuis cinquante ans : des petites exploitations familiales aux droits à paiement unique. Référence, INSEE (Eds) 7-30.
- DeVries, T.J., Beauchemin, K.A., Dohme, F., Schwartzkopf-Genswein, K.S., 2009. Repeated ruminal acidosis challenges in lactating dairy cows at high and low risk for developing acidosis: Feeding, ruminating, and lying behavior. *J. Dairy Sci.* 92, 5067–5078. <https://doi.org/10.3168/jds.2009-2102>
- Dieulot, R., 2013. Résultats de l'observatoire technicoéconomique du RAD. *Exerc. Comptab.* 2013 16.
- Dillon, P., 2011. The dairy industry: planning for 2020. Presented at the Proceedings of the Teagasc national dairy conference, Cork and Athlone, pp. 1–25.
- Dockes, A.C., Kling-Eveillard, F., Jacquinet, M., Beche, J.M., 2007. Consommateurs et éleveurs de bovins face à la problématique du bien-être animal. Presented at the Rencontre, Recherche, Ruminants, pp. 285–292.
- Dolecheck, K.A., Heersche, G., Bewley, J.M., 2013. Investment analysis of automated estrus detection technologies. Presented at the Proceedings of the precision dairy conference and expo., University of Minnesota, Mayo Civic Center, Rochester, Minnesota, pp. 103–104.
- Dutta, R., Smith, D., Rawnsley, R., Bishop-Hurley, G., Hills, J., Timms, G., Henry, D., 2015. Dynamic cattle behavioural classification using supervised ensemble classifiers. *Comput. Electron. Agric.* 18–28. <http://dx.doi.org/10.1016/j.compag.2014.12.002>
- Erdaş, Ç.B., Atasoy, I., Açııcı, K., Oğul, H., 2016. Integrating Features for Accelerometer-based Activity Recognition. *Procedia Comput. Sci.* 98, 522–527. <https://doi.org/10.1016/j.procs.2016.09.070>
- Farm Animal Welfare Committee (FAWC) [WWW Document], 2011. URL <https://www.gov.uk/government/groups/farm-animal-welfare-committee-fawc>
- Fida, B., Bernabucci, I., Bibbo, D., Conforto, S., Schmid, M., 2015. Pre-Processing Effect on the Accuracy of Event-Based Activity Segmentation and Classification through Inertial Sensors. *Sensors* 15, 23095–23109. <https://doi.org/10.3390/s150923095>
- FranceAgriMer, 2019. Consommation de produits laitiers en 2018.
- French, P., O'Brien, B., Shalloo, L., 2015. Development and adoption of new technologies to increase the efficiency and sustainability of pasture-based systems. *Anim. Prod. Sci.* 55, 931. <https://doi.org/10.1071/AN14896>

- Friggens, N., Bjerring, M., Ridder, C., Hjsgaard, S., Larsen, T., 2008. Improved Detection of Reproductive Status in Dairy Cows Using Milk Progesterone Measurements. *Reprod. Domest. Anim.* 43, 113–121. <https://doi.org/10.1111/j.1439-0531.2008.01150.x>
- Gac, A., Dollé, J.-B., Le Gall, A., Klumpp, K., Tallec, T., Mousset, J., Eglin, T., Bispo, A., Peyraud, J.L., Faverdin, P., 2010. Le stockage de Carbone par les prairies : Une voie d'atténuation de l'impact de l'élevage herbivore sur l'effet de serre.
- Galindo, F., Broom, D.M., 2002. The Effects of Lameness on Social and Individual Behavior of Dairy Cows. *J. Appl. Anim. Welf. Sci.* 5, 193–201. https://doi.org/10.1207/S15327604JAWS0503_03
- Ganskopp, D.C., Johnson, D.D., 2007. GPS Error in Studies Addressing Animal Movements and Activities. *Rangel. Ecol. Manag.* 60, 350–358.
- Gibb, M.J., Huckle, C.A., Nuthall, R., Rook, A.J., 1999. The effect of physiological state lactating or dry/ and sward surface height on grazing behaviour and intake by dairy cows. *Appl. Anim. Behav. Sci.* 63, 269–287.
- Giovanetti, V., Decandia, M., Molle, G., Acciaro, M., Mameli, M., Cabiddu, A., Cossu, R., Serra, M.G., Manca, C., Rassu, S.P.G., Dimauro, C., 2017. Automatic classification system for grazing, ruminating and resting behaviour of dairy sheep using a tri-axial accelerometer. *Livest. Sci.* 196, 42–48. <https://doi.org/10.1016/j.livsci.2016.12.011>
- Gliessman, S., 2018. Defining Agroecology. *Agroecol. Sustain. Food Syst.* 42, 599–600. <https://doi.org/10.1080/21683565.2018.1432329>
- Gonzalez, L.A., Bishop-Hurley, G.J., Handcock, R.N., Crossman, C., 2015. Behavioral classification of data from collars containing motion sensors in grazing cattle. *Comput. Electron. Agric.* 91–102. <http://dx.doi.org/10.1016/j.compag.2014.10.018>
- Hamalainen, W., Jarvinen, M., Martiskainen, P., Mononen, J., 2011. Jerk-based feature extraction for robust activity recognition from acceleration data, in: 2011 11th International Conference on Intelligent Systems Design and Applications. Presented at the 2011 11th International Conference on Intelligent Systems Design and Applications (ISDA), IEEE, Cordoba, Spain, pp. 831–836. <https://doi.org/10.1109/ISDA.2011.6121760>
- Hamäläinen, W., Järvinen, M., Martiskainen, P., Mononen, J., 2011. Jerk-based feature extraction for robust activity recognition from acceleration data, in: Intelligent Systems Design and Applications (ISDA), 2011 11th International Conference On. IEEE, pp. 831–836.
- Hastie, T., Tibshirani, R., Friedman, J., 2011. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, Springer Series in Statistics.
- Hills, J.L., Rawnsley, R., Harrison, M.T., Bishop-Hurley, G.J., Henry, D.A., Raedts, P., Freeman, M., Roche, J.R., 2016. Precision feeding and grazing management for temperate pasture-based dairy systems. *Precis. Dairy Farming*.
- Hokkanen, A.-H., Hänninen, L., Tiisanen, J., Pastell, M., 2011. Predicting sleep and lying time of calves with a support vector machine classifier using accelerometer data. *Appl. Anim. Behav. Sci.* 134, 10–15. <https://doi.org/10.1016/j.applanim.2011.06.016>
- Huyghe, C., 2009. La multifonctionnalité des prairies en France II. Conciliation des fonctions de production et de préservation de l'environnement. *Cah. Agric.* 18, 7–16. <https://doi.org/10.1684/agr.2009.0263>
- Kammaing, J.W., Le, D.V., Meijers, J.P., Bisby, H., Meratnia, N., Havinga, P.J.M., 2018. Robust Sensor-Oriented-Independent Feature Selection for Animal Activity Recognition on Collar Tags. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.* 2, 1–27. <https://doi.org/10.1145/3191747>
- Kennedy, E., Curran, J., Mayes, B., McEvoy, M., Murphy, J.P., O'Donovan, M., 2011. Restricting dairy cow access time to pasture in early lactation: the effects on milk

- production, grazing behaviour and dry matter intake. *Animal* 1805–1813. <https://doi.org/10.1017/S1751731111000826>
- Kennedy, E., McEvoy, M., Murphy, J.P., O'Donovan, M., 2009. Effect of restricted access time to pasture on dairy cow milk production, grazing behavior, and dry matter intake. *J. Dairy Sci.* 92, 168–176. <https://doi.org/10.3168/jds.2008-1091>
- Keogh, E., Chu, S., Hart, D., Pazzani, M., 2001. An online algorithm for segmenting time series, in: *Proceedings 2001 IEEE International Conference on Data Mining*. Presented at the 2001 IEEE International Conference on Data Mining, IEEE Comput. Soc, San Jose, CA, USA, pp. 289–296. <https://doi.org/10.1109/ICDM.2001.989531>
- La France Agricole. La tétanie d'herbage [WWW Document], 2005. . Fr. Agric. URL <http://www.lafranceagricole.fr/article/la-tetanie-d-herbage-1,0,42532991.html>
- Laca, E.A., 2009. Precision livestock production: tools and concepts. *Rev. Bras. Zootec.* 38, 123–132. <https://doi.org/10.1590/S1516-35982009001300014>
- Larson-Praplan, S., George, M.R., Buckhouse, J.C., Laca, E.A., 2015. Spatial and temporal domains of scale of grazing cattle. *Anim. Prod. Sci.* <http://dx.doi.org/10.1071/AN14641>
- Le Gall, A., Faverdin, P., Thomet, P., Verité, R., 2001. Le pâturage en Nouvelle-Zélande : des idées pour les régions arrosées d'Europe 21.
- Le Roux, X., 2008. Agriculture et biodiversité. Valoriser les synergies. *Expert. Sci. Collect.* 117.
- Leray, O., Doligez, P., Jost, J., Pottier, E., Delaby, L., 2017. Présentation des différentes techniques de pâturage selon les espèces herbivores utilisatrices 7.
- LIT OUESTEREL, 2019. Laboratoire d'Innovation Territorial « Ouest Territoires d'Élevage ».
- Lush, L., Wilson, R.P., Holton, M.D., Hopkins, P., Marsden, K.A., Chadwick, D.R., King, A.J., 2018. Classification of sheep urination events using accelerometers to aid improved measurements of livestock contributions to nitrous oxide emissions. *Comput. Electron. Agric.* 150, 170–177. <https://doi.org/10.1016/j.compag.2018.04.018>
- Manning, J., Cronin, G., González, L., Hall, E., Merchant, A., Ingram, L., 2017. The Behavioural Responses of Beef Cattle (*Bos taurus*) to Declining Pasture Availability and the Use of GNSS Technology to Determine Grazing Preference. *Agriculture* 7, 45. <https://doi.org/10.3390/agriculture7050045>
- Marsh, R.E., 1999. Fenceless animal control system using GPS location information. 5,868,100,.
- Martiskainen, P., Järvinen, M., Skön, J.P., Tiirikainen, J., Kolehmainen, M., Mononen, J., 2009. Cow behaviour pattern recognition using a three-dimensional accelerometer and support vector machines. *Appl. Anim. Behav. Sci.* 119, 32–38.
- Mattachini, G., Riva, E., Perazzolo, F., Naldi, E., Provolo, G., 2016. Monitoring feeding behaviour of dairy cows using accelerometers. *J. Agric. Eng.* 47, 54. <https://doi.org/10.4081/jae.2016.498>
- McSweeney, D., Foley, C., Halton, P., O'Brien, B., 2015. Calibration of an automated grass measurement tool to enhance the precision of grass measurement in pasture based farming systems. Presented at the Teagasc Ag conference, Tullamore.
- Meuret, M., Tichit, M., Hostiou, N., 2013. élevage et pâturage « de précision » : l'animal sous surveillance électronique 12.
- Milone, D.H., Galli, J.R., Cangiano, C.A., Rufiner, H.L., Laca, E.A., 2012. Automatic recognition of ingestive sounds of cattle based on hidden Markov models. *Comput. Electron. Agric.* 87, 51–55. <https://doi.org/10.1016/j.compag.2012.05.004>
- Moreau, M., Siebert, S., Buerkert, A., Schlecht, E., 2009. Use of a tri-axial accelerometer for automated recording and classification of goats' grazing behaviour. *Appl. Anim. Behav. Sci.* 119, 158–170. <https://doi.org/10.1016/j.applanim.2009.04.008>

- Munksgaard, L., Simonsen, H.B., 1996. Behavioral and pituitary adrenal-axis responses of dairy cows to social isolation and deprivation of lying down. *J. Anim. Sci.* 74, 769. <https://doi.org/10.2527/1996.744769x>
- Nadimi, E.S., Søgaaard, H.T., Bak, T., 2008. ZigBee-based wireless sensor networks for classifying the behaviour of a herd of animals using classification trees. *Biosyst. Eng.* 100, 167–176. <https://doi.org/10.1016/j.biosystemseng.2008.03.003>
- Nadin, L.B., Chopra, F.S., Gibb, M.J., Trindade, J.K. da, Amaral, G.A. do, de Faccio Carvalho, P.C., Gonda, H.L., 2012. Comparison of methods to quantify the number of bites in calves grazing winter oats with different sward heights. *Appl. Anim. Behav. Sci.* 139, 50–57. <https://doi.org/10.1016/j.applanim.2012.03.001>
- Navon, S., Mizrach, A., Hetzroni, A., Ungar, E.D., 2013. Automatic recognition of jaw movements in free-ranging cattle, goats and sheep, using acoustic monitoring. *Biosyst. Eng.* 114, 474–483. <https://doi.org/10.1016/j.biosystemseng.2012.08.005>
- Nitsch, H., Osterburg, B., Roggendorf, W., Laggner, B., 2012. Cross compliance and the protection of grassland – Illustrative analyses of land use transitions between permanent grassland and arable land in German regions. *Land Use Policy* 29, 440–448. <https://doi.org/10.1016/j.landusepol.2011.09.001>
- O’Brien, D., Shalloo, L., Patton, J., Buckley, F., Grainger, C., Wallace, M., 2012. A life cycle assessment of seasonal grass-based and confinement dairy farms. *Agric. Syst.* 107, 33–46. <https://doi.org/10.1016/j.agsy.2011.11.004>
- O’Driscoll, K., Lewis, E., Kennedy, E., 2019. Effect of feed allowance at pasture on the lying behaviour of dairy cows. *Appl. Anim. Behav. Sci.* 213, 40–46. <https://doi.org/10.1016/j.applanim.2019.02.002>
- O’Mara, F.P., 2012. The role of grasslands in food security and climate change. *Ann. Bot.* 110, 1263–1270. <https://doi.org/10.1093/aob/mcs209>
- Penning, P.D., 1983. A technique to record automatically some aspects of grazing and ruminating behaviour in sheep. *Grass Forage Sci.* 38, 89–96. <https://doi.org/10.1111/j.1365-2494.1983.tb01626.x>
- Pflimlin, A., Faverdin, P., Béranger, C., 2009. Un demi-siècle d’évolution de l’élevage bovin. *Bilan et perspectives* 36.
- Pflimlin, A., Hubert, B., Leaver, D., 2001. Pâturage : importance actuelle et nouveaux enjeux 13.
- Pietka, E., 1988. Expert systems in parameter extraction of the ECG signal, in: In Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Presented at the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, New Orleans, LA, USA, pp. 165–166.
- Putfarken, D., Dengler, J., Lehmann, S., Härdtle, W., 2008. Site use of grazing cattle and sheep in a large-scale pasture landscape: A GPS/GIS assessment. *Appl. Anim. Behav. Sci.* 111, 54–67. <https://doi.org/10.1016/j.applanim.2007.05.012>
- Rahman, A., Smith, D.V., Little, B., Ingham, A.B., Greenwood, P.L., Bishop-Hurley, G.J., 2018. Cattle behaviour classification from collar, halter, and ear tag sensors. *Inf. Process. Agric.* 5, 124–133. <https://doi.org/10.1016/j.inpa.2017.10.001>
- Ribeiro Filho, H.M.N., Setelich, E.A., Crestani, S., Dias, K.M., Mantovani, C., Valenti, J., 2011. Relationship between diurnal grazing time and herbage intake in dairy cows in rotational grazing. *Ciênc. Rural St. Maria* 41.
- Robert, B., White, B.J., Renter, D.G., Larson, R.L., 2009. Evaluation of three-dimensional accelerometers to monitor and classify behavior patterns in cattle. *Comput. Electron. Agric.* 67, 80–84.
- Rook, A.J., Tallowin, J.R.B., 2003. Grazing and pasture management for biodiversity benefit. *Anim. Res.* 52, 181–189. <https://doi.org/10.1051/animres:2003014>

- Rushen, J., Chapinal, N., de Passillé, A., 2012. Automated monitoring of behavioural-based animal welfare indicators. *Anim. Welf.* 21, 339–350. <https://doi.org/10.7120/09627286.21.3.339>
- Rutten, C.J., Velthuis, A.G.J., Steeneveld, W., Hogeveen, H., 2013. Sensors to support health management on dairy farms. *J. Dairy Sci.* 1928–1952.
- Rutter, S.M., 2000. Graze: A program to analyze recordings of the jaw movements of ruminants. *Behav. Res. Methods Instrum. Comput.* 32, 86–92. <https://doi.org/10.3758/BF03200791>
- Rutter, S.M., Champion, R.A., Penning, P.D., 1997. An automatic system to record foraging behaviour in free-ranging ruminants. *Appl. Anim. Behav. Sci.* 54, 185–195. [https://doi.org/10.1016/S0168-1591\(96\)01191-4](https://doi.org/10.1016/S0168-1591(96)01191-4)
- Schneider, A., Huyghe, C., 2015. Les légumineuses pour des systèmes agricoles et alimentaires durables. éditions Quae. <https://doi.org/10.35690/978-2-7592-2335-0>
- Schütz, K.E., Rogers, A.R., Poulouin, Y.A., Cox, N.R., Tucker, C.B., 2010. The amount of shade influences the behavior and physiology of dairy cattle 93, 9.
- Sellers, W.I., Crompton, R.H., 2004. Automatic Monitoring of Primate Locomotor Behaviour Using Accelerometers. *Folia Primatol. (Basel)* 75, 279–293. <https://doi.org/10.1159/000078939>
- Seuret, J.-M., Theau, J.-P., Pottier, E., Pelletier, P., Piquet, M., Delaby, L., 2014. Des outils d'aide à la gestion du pâturage pour mieux valoriser les prairies et renforcer la confiance des éleveurs. *Fourrages* 218, 191–201.
- Siiivonen, J., Taponen, S., Hovinen, M., Pastell, M., Lensink, B.J., Pyörälä, S., Hänninen, L., 2011. Impact of acute clinical mastitis on cow behaviour. *Appl. Anim. Behav. Sci.* 132, 101–106. <https://doi.org/10.1016/j.applanim.2011.04.005>
- Smith, D., Rahman, A., Bishop-Hurley, G.J., Hills, J., Shahriar, S., Henry, D., Rawnsley, R., 2016. Behavior classification of cows fitted with motion collars: Decomposing multi-class classification into a set of binary problems. *Comput. Electron. Agric.* 131, 40–50. <https://doi.org/10.1016/j.compag.2016.10.006>
- Umstatter, C., 2011. The evolution of virtual fences: A review. *Comput. Electron. Agric.* 75, 10–22. <https://doi.org/10.1016/j.compag.2010.10.005>
- Vázquez Diosdado, J.A., Barker, Z.E., Hodges, H.R., Amory, J.R., Croft, D.P., Bell, N.J., Codling, E.A., 2015. Classification of behaviour in housed dairy cows using an accelerometer-based activity monitoring system. *Anim. Biotelemetry* 3. <https://doi.org/10.1186/s40317-015-0045-8>
- Venturi, R., 2015. The Digital Revolution – An Industrial Revolution? *France Stratégie*.
- Watanabe, N., Sakanoue, S., Kawamura, K., Kozakai, T., 2008. Development of an automatic classification system for eating, ruminating and resting behavior of cattle using an accelerometer. *Grassl. Sci.* 7.
- Webster, J., Stewart, M., Rogers, A., Verkerk, G., 2008. Assessment of welfare from physiological and behavioural responses of New Zealand dairy cows exposed to cold and wet conditions. *Anim. Welf.* 8.
- Wechsler, B., 1995. Coping and coping strategies: a behavioural view. *Appl. Anim. Behav. Sci.* 43, 123–134. [https://doi.org/10.1016/0168-1591\(95\)00557-9](https://doi.org/10.1016/0168-1591(95)00557-9)
- Weizheng, S., Fei, C., Yu, Z., Xiaoli, W., Qiang, F., Yonggen, Z., 2019. Automatic recognition of ingestive-related behaviors of dairy cows based on triaxial acceleration. *Inf. Process. Agric.* S2214317319301921. <https://doi.org/10.1016/j.inpa.2019.10.004>
- Werner, J., Leso, L., Umstatter, C., Niederhauser, J., Kennedy, E., Geoghegan, A., Shalloo, L., Schick, M., O'Brien, B., 2018. Evaluation of the RumiWatchSystem for measuring grazing behaviour of cows. *J. Neurosci. Methods* 300, 138–146. <https://doi.org/10.1016/j.jneumeth.2017.08.022>

- Werner, J., Umstatter, C., Kennedy, E., Grant, J., Leso, L., Geoghegan, A., Shalloo, L., Schick, M., O'Brien, B., 2019. Identification of possible cow grazing behaviour indicators for restricted grass availability in a pasture-based spring calving dairy system. *Livest. Sci.* 220, 74–82. <https://doi.org/10.1016/j.livsci.2018.12.004>
- Williams, L.R., Fox, D.R., Bishop-Hurley, G.J., Swain, D.L., 2019. Use of radio frequency identification (RFID) technology to record grazing beef cattle water point use. *Comput. Electron. Agric.* 156, 193–202. <https://doi.org/10.1016/j.compag.2018.11.025>
- Yang, J., 2009. Toward physical activity diary: motion recognition using simple acceleration features with mobile phones, in: *Proceedings of the 1st International Workshop on Interactive Multimedia for Consumer Electronics*. ACM, pp. 1–10.
- Yunta, C., Guasch, I., Bach, A., 2012. Short communication: Lying behavior of lactating dairy cows is influenced by lameness especially around feeding time. *J. Dairy Sci.* 95, 6546–6549. <https://doi.org/10.3168/jds.2012-5670>
- Zebari, H.M., Rutter, S.M., Bleach, E.C.L., 2018. Characterizing changes in activity and feeding behaviour of lactating dairy cows during behavioural and silent oestrus. *Appl. Anim. Behav. Sci.* 206, 12–17. <https://doi.org/10.1016/j.applanim.2018.06.002>

Chapitre 2 : Questions et stratégie de recherche

1. Contexte de l'étude

Optimiser la valorisation de la prairie en élevage de bovins laitiers par le pâturage et améliorer le bien-être et la santé des animaux constituent des piliers de la transition agroécologique (Claveirole, 2016). La gestion du pâturage est néanmoins compliquée et conditionne directement les bénéfices attendus, justifiant de développer des outils pour accompagner les éleveurs dans leur prise de décision (Seuret et al., 2014). A ce propos, des outils numériques se développent pour faciliter la gestion du pâturage dans le cadre de l'élevage de précision (Laca, 2009) mais ces outils restent marginaux et leur plus-value est souvent mal perçue par les éleveurs. Il semble donc légitime de développer un nouvel outil dans son intégralité.

Remonter des informations en continu sur le comportement et la position des vaches laitières pour appréhender un challenge interne ou externe au pâturage semble constituer une stratégie pertinente (Rushen et al., 2012). Ces informations peuvent être obtenues à partir d'accéléromètres (Martiskainen et al., 2009) et GPS (Putfarken et al., 2008) embarqués, à condition de mettre en place des techniques d'analyses adaptées. Une méthodologie en quatre étapes classiquement utilisée dans la littérature pour classifier les comportements des ruminants à partir de données accéléromètres a été identifiée (Brown et al., 2013). Plusieurs techniques ont néanmoins été envisagées à chaque étape et aboutissent à des performances de classification différentes. En terme de protocole, la position du capteur et la fréquence d'échantillonnage doivent être dûment réfléchies en fonction des objectifs de l'étude. En terme de traitement, la taille de la fenêtre pour la segmentation influence les performances de classification et reste dans tous les cas étude-dépendante. Il convient également de rappeler qu'un ensemble de méthodes de traitement des données accéléromètres brutes, non explorées dans la communauté concernée, sont couramment utilisées dans des domaines connexes (Quante et al., 2015). Parmi les classifieurs testés en classification de ruminants, les méthodes de ML, particulièrement le classifieur SVM et les méthodes ensemblistes, sont à prioriser. Une combinaison pertinente de ces différentes méthodes mérite donc d'être explorée en vue de répondre aux deux freins majeurs au développement de ces outils, à savoir :

- (1) Le faible nombre de comportements pouvant être prédits de manière robuste
- (2) La validité des modèles développés à l'échelle de la période et de l'individu

2. Questions et objectifs

Ce travail a été réalisé en vue de répondre à deux questions de recherche :

- (1) Quelle combinaison de méthodes (traitement du signal, algorithmes de classification, etc.) permettrait de classer le comportement des vaches laitières au pâturage en levant les deux verrous exposés dans la littérature ? La combinaison optimale sera nommée « cadre méthodologique » par la suite.
- (2) Quel est le potentiel du cadre méthodologique combiné à des données de position des animaux pour répondre au moins à l'une des applications envisagées ? A savoir :
 - Evaluer l'état de la ressource sur la parcelle en vue de faciliter la prise de décision des changements de parcelles en pâturage tournant.
 - Assurer un suivi automatisé du bien-être et de la santé des animaux au pâturage.

3. Stratégie mise en place

Partie expérimentale.

La première partie consistait à collecter les données expérimentales nécessaires pour répondre aux deux problématiques (étape 1 ; Figure 13). Pour ceci, 86 vaches laitières issues de 4 élevages commerciaux de la région Pays-de-la-Loire ont été équipées au cours des printemps/étés 2017 et 2018 avec un boîtier fixé sur un collier et comprenant un accéléromètre 3 D (fréquence d'échantillonnage : 59.5 Hz ; > 20 Hz ; théorème de Shannon) et un capteur GPS (fréquence d'échantillonnage : 1 Hz). Le positionnement de l'accéléromètre au niveau du cou devrait ainsi permettre de remonter des informations sur le comportement d'ingestion, de rumination et de repos (Dutta et al., 2015). Comme suggéré par Hamalainen et al. (2011), les postures des animaux devraient également pouvoir être identifiées à partir de modèles adaptés. Afin de pouvoir coupler le signal accéléromètre avec le comportement des animaux, les 86 vaches laitières équipées ont été observées alternativement par deux expérimentateurs sur des sessions continues de 15 minutes. Les comportements observés ainsi que les heures de début et de fin (précision à la seconde) associées ont été notés. Chacun des comportements a été défini au préalable dans un éthogramme. Plus de 57 heures d'observation sur les 86 animaux ont ainsi été réalisées.

Afin de répondre à la question de recherche (2), 26 vaches laitières de l'un des 4 élevages ont également été équipées avec le même dispositif pendant 5 jours de pâturage, correspondant à une rotation complète. La ration des animaux était constituée en majeure partie d'herbe pâturée, avec une conduite de pâturage très libérale (27.5 kg MS/vache/jour). Les animaux

Chapitre 2

avaient accès à deux prairies au cours de la rotation. La première était une prairie temporaire présentant peu d'éléments structurants et un couvert végétal limité aux espèces semées (brome mou, ray-grass anglais, trèfle blanc) et aux adventices. Cette parcelle était située à proximité du robot de traite, du bâtiment et des génisses et était pâturée sur le créneau de l'après-midi. La seconde était une prairie permanente présentant au contraire de nombreux éléments structurants (arbres et haies), des zones humides, en pente et une diversité floristique très marquée. Cette parcelle était pâturée sur le créneau du matin. Les éléments structurants et les caractéristiques floristiques ont été identifiés et géolocalisés dans chacune des prairies.

Partie méthodologique.

La seconde partie consiste à mettre en place les traitements nécessaires pour répondre aux deux questions de recherche à partir des données expérimentales collectées. Un premier travail sur le traitement du signal (étape 2 ; Figure 13) a d'abord été réalisé en vue de :

- Evaluer la pertinence de certaines approches utilisées dans la littérature et confirmer les effets déjà testés.
- Evaluer l'impact de quelques techniques de traitement du signal classiquement rencontrées en reconnaissance des activités humaines sur la qualité de la classification des comportements de ruminants.

Une seconde étude a ensuite été réalisée afin d'identifier la combinaison de pré-traitement et de modèles de classification qui permette de classifier l'ensemble des comportements principaux des vaches laitières de façon robuste. Ce travail visait ainsi à :

- Tester différentes configurations de traitements du signal en se basant sur les résultats de l'étude précédente.
- Comparer les performances de plusieurs algorithmes de classification supervisée et de méthodes ensemblistes de ML (étape 3 ; Figure 13).
- Evaluer l'intérêt d'un lissage *a posteriori* qui tienne compte de la structure temporelle au sein d'une séquence continue de comportements (étape 3 ; Figure 13).
- Evaluer la prédiction *via* des techniques de validation adaptées (étape 4 ; Figure 13).

Le potentiel du cadre méthodologique pour la détection d'un trouble de confort a finalement été évalué (problématique (2)). Pour cela, une dernière étude visant à relier les comportements exprimés au pâturage avec les caractéristiques des prairies a été réalisée. En supposant qu'un lien cohérent puisse être établi, la méthodologie couplée à la position des vaches laitières pourrait alors permettre de détecter des changements de comportements liés à un défaut de confort au pâturage.

Chapitre 2

Les trois études mentionnées font l'objet des chapitres 3, 4 et 5, respectivement. Ces trois chapitres correspondent aux articles scientifiques acceptés ou soumis dans des journaux scientifiques.

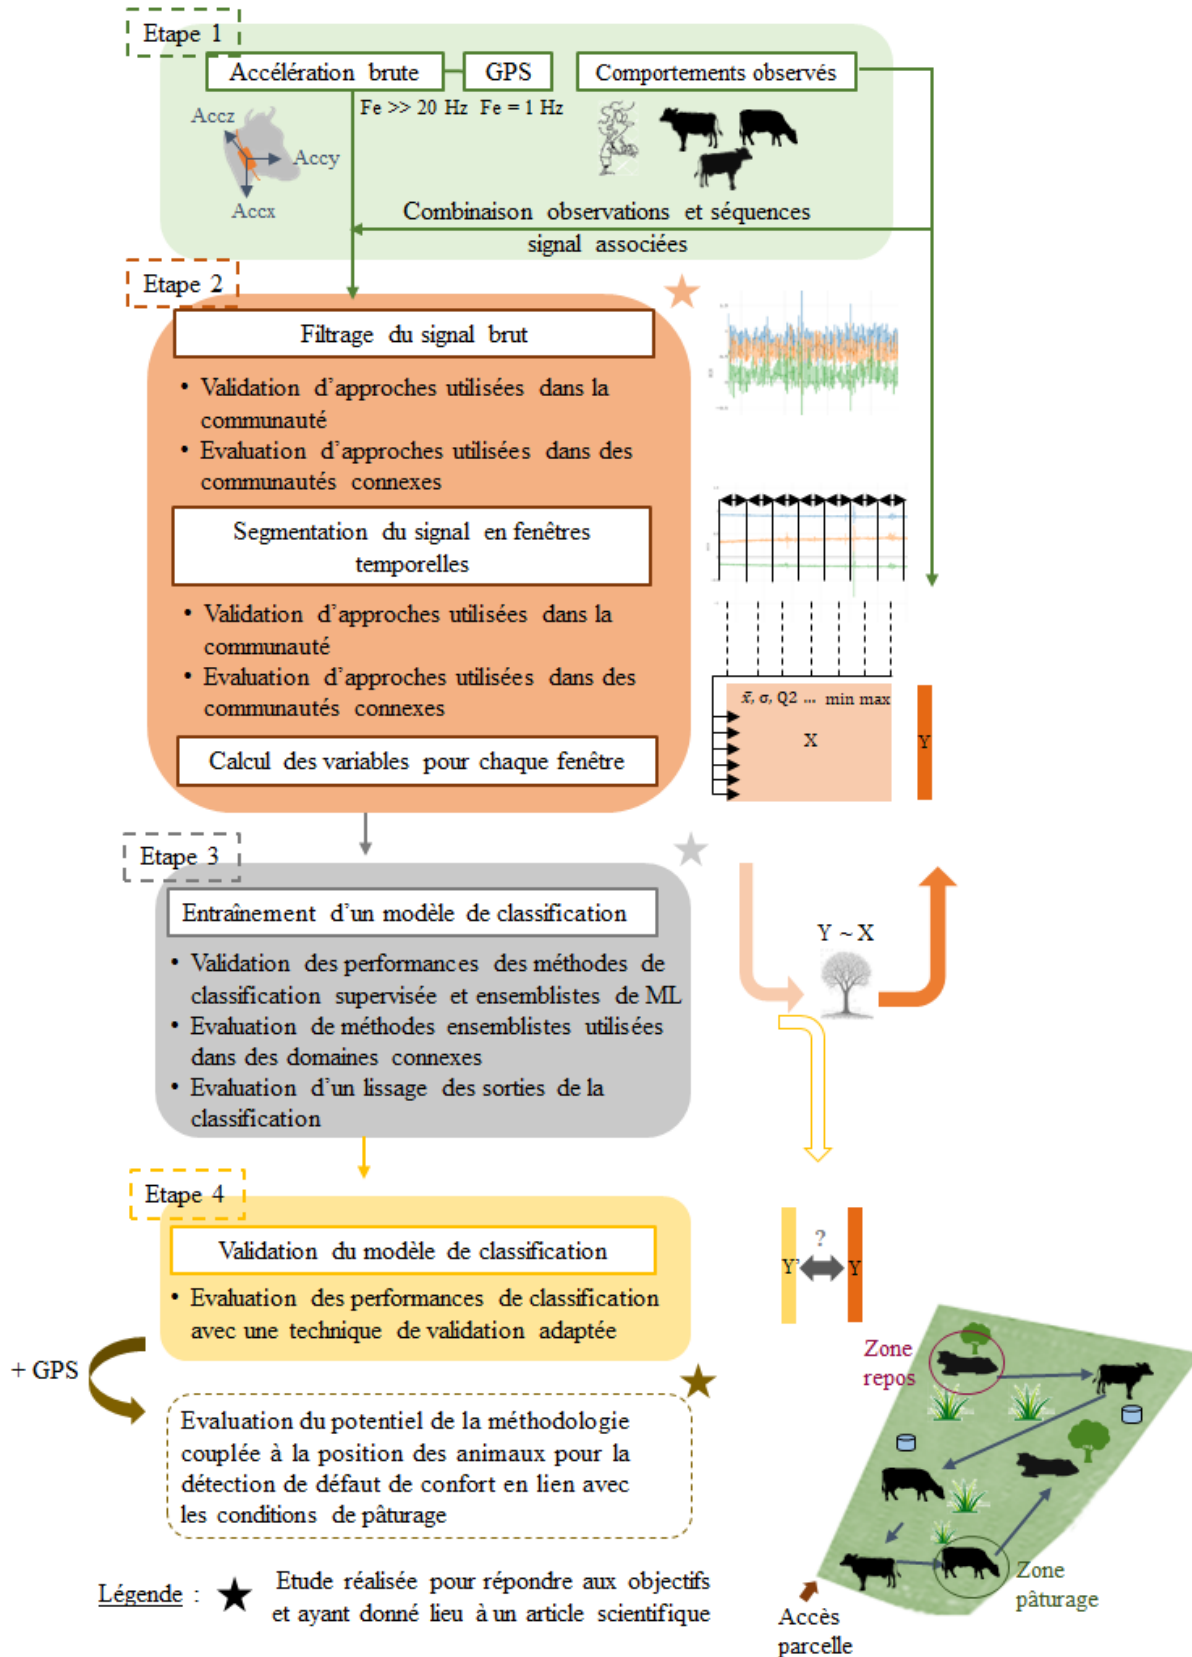


Figure 13. Vue d'ensemble sur la démarche scientifique mise en œuvre

Références

- Brown, D.D., Kays, R., Wikelski, M., Wilson, R., Klimley, A.P., 2013. Observing the unwatchable through acceleration logging of animal behavior. *Anim. Biotelemetry* 16p.
- Claveirole, C., 2016. La transition agroécologique : défis et enjeux (No. CESL1100013X). Conseil économique, social et environnemental.
- Dutta, R., Smith, D., Rawnsley, R., Bishop-Hurley, G., Hills, J., Timms, G., Henry, D., 2015. Dynamic cattle behavioural classification using supervised ensemble classifiers. *Comput. Electron. Agric.* 18–28. <http://dx.doi.org/10.1016/j.compag.2014.12.002>
- Hamalainen, W., Jarvinen, M., Martiskainen, P., Mononen, J., 2011. Jerk-based feature extraction for robust activity recognition from acceleration data, in: 2011 11th International Conference on Intelligent Systems Design and Applications. Presented at the 2011 11th International Conference on Intelligent Systems Design and Applications (ISDA), IEEE, Cordoba, Spain, pp. 831–836. <https://doi.org/10.1109/ISDA.2011.6121760>
- Laca, E.A., 2009. Precision livestock production: tools and concepts. *Rev. Bras. Zootec.* 38, 123–132. <https://doi.org/10.1590/S1516-35982009001300014>
- Martiskainen, P., Järvinen, M., Skön, J.P., Tiirikainen, J., Kolehmainen, M., Mononen, J., 2009. Cow behaviour pattern recognition using a three-dimensional accelerometer and support vector machines. *Appl. Anim. Behav. Sci.* 119, 32–38.
- Putfarken, D., Dengler, J., Lehmann, S., Härdtle, W., 2008. Site use of grazing cattle and sheep in a large-scale pasture landscape: A GPS/GIS assessment. *Appl. Anim. Behav. Sci.* 111, 54–67. <https://doi.org/10.1016/j.applanim.2007.05.012>
- Rushen, J., Chapinal, N., de Passillé, A., 2012. Automated monitoring of behavioural-based animal welfare indicators. *Anim. Welf.* 21, 339–350. <https://doi.org/10.7120/09627286.21.3.339>
- Seuret, J.-M., Theau, J.-P., Pottier, E., Pelletier, P., Piquet, M., Delaby, L., 2014. Des outils d'aide à la gestion du pâturage pour mieux valoriser les prairies et renforcer la confiance des éleveurs. *Fourrages* 218, 191–201.

Chapitre 3 : Evaluation de l'effet du traitement du signal brut sur les performances de prédiction des comportements des ruminants

1. Contexte de l'étude

L'entraînement des algorithmes de classification supervisée de ML nécessite de fournir en entrée un jeu de données qui soit le plus approprié possible, c'est-à-dire qui contienne un ensemble de variables résumant au mieux l'information portée par chacune des fenêtres de signal associée à un comportement observé. Dans la communauté concernée, l'étape qui permet de passer des données accéléromètres brutes au jeu de données, appelée ici le traitement du signal brut, consiste dans ce cas à (1) éventuellement filtrer le signal afin d'extraire des séries temporelles particulières, (2) segmenter le signal en fenêtres de taille fixe et (3) calculer un ensemble de variables pour chaque fenêtre. Les fenêtres sont ensuite associées aux comportements observés afin de constituer le jeu de données complet qui sera utilisé pour entraîner les modèles de classification.

Une diversité de méthodes pouvant être mise en œuvre à chacune des trois étapes, il semble légitime de se demander si certaines approches sont à privilégier pour optimiser les performances des algorithmes de classification. Cette question, déjà traitée en reconnaissance des activités humaines (Quante et al., 2015), a été en revanche relativement peu abordée dans la communauté concernée. En particulier, la segmentation est généralement réalisée sur le signal accéléromètre brut (Barwick et al., 2018; Robert et al., 2009) ou sur les accélérations statiques et dynamiques isolées par filtrage (Lush et al., 2018; Smith et al., 2016). A noter que la composante statique est parfois exclue de l'analyse (Benaïssa et al., 2018). De la même façon, la réduction de bruit dans le signal, généralement mise en œuvre dans les domaines connexes (Benson et al., 2018), n'a été rencontrée qu'une seule fois dans la communauté concernée (Andriamandroso et al., 2017) et son effet n'a pas été évalué.

Concernant la segmentation, une diversité d'approches peut être mise en œuvre, comme des segmentations en fenêtres de taille fixe avec ou sans recouvrement (Bersch et al., 2014), des segmentations dynamiques (Kozina et al., 2011) ou des segmentations par partitionnement (Keogh et al., 2001). La littérature sur la classification des comportements de ruminants utilise exclusivement des segmentations de taille fixe sans recouvrement. A ce propos, le recouvrement entre fenêtres, consistant à conserver un certain pourcentage de données commun

entre deux fenêtres successives, est pourtant relativement simple à mettre en œuvre et devrait améliorer les performances des algorithmes *via* une augmentation directe du volume de données pour l'apprentissage du modèle (Bersch et al., 2014). Son effet mériterait donc d'être exploré, au même titre que celui de la taille de la fenêtre, déjà étudié dans plusieurs études (Decandia et al., 2018; Robert et al., 2009). Une meilleure compréhension de ces différents effets amènerait donc un éclairage pertinent sur les différentes techniques de traitement du signal à privilégier dans les prochaines études.

2. Objectifs

Cette étude a pour objectif d'évaluer l'effet du traitement du signal sur les performances de classification et d'identifier les techniques les plus appropriées dans ce contexte.

3. Stratégie

L'attention a été portée sur des techniques de filtrage et de segmentation fixe. Concernant l'étape de filtrage, cette étude consiste (1) à évaluer l'intérêt de travailler à partir du signal brut ou de l'accélération dynamique exclusivement et (2) à évaluer l'effet d'une réduction du niveau de bruit du signal. Concernant l'étape de segmentation, le travail vise (1) à évaluer l'effet du recouvrement entre fenêtres de taille fixe et (2) à confirmer l'effet de la taille de la fenêtre.

4. Démarche

Une vue d'ensemble sur la méthodologie est proposée dans la Figure 14. Les données accéléromètres de 10 vaches laitières issues d'un des 4 élevages, couplées à cinq heures d'observation, ont été utilisées. Concernant l'étape de filtrage, trois approches ont été envisagées :

- Aucun filtrage, afin d'évaluer la pratique la plus couramment mise en œuvre dans la communauté concernée.
- Un filtrage passe-haut à 0.3 Hz pour exclure la composante statique afin d'évaluer l'intérêt d'un travail exclusif sur la composante dynamique.
- Un filtrage passe bas à 5 et 10 Hz pour évaluer l'effet d'une réduction de bruit à deux fréquences de coupure différentes.

Concernant l'étape de segmentation, la méthodologie mise en œuvre a consisté à :

- Tester différents pourcentages de recouvrement, de 0 % à 90 %.

Chapitre 3

- Tester différentes tailles de fenêtre, de 3 s à 30 s.

En combinant toutes les possibilités, 150 configurations différentes ont été obtenues. Les mêmes variables ont été extraites pour chacune de ces configurations. Chacun des 150 jeux de données a servi de support à l'entraînement d'un arbre de décision pour classer quatre comportements des vaches laitières au pâturage. Le principe de cet algorithme est proposé en Annexe VI. Une évaluation des résultats par validation croisée a permis de calculer des métriques de performance (pourcentage de bon classement, Fscore, sensibilité, spécificité, précision) qui ont par suite été utilisées pour comparer les prédictions obtenues avec chacune des 150 configurations de traitement. Un modèle linéaire et une analyse de la variance ont été réalisés afin d'estimer chacun des effets et leur niveau de significativité.

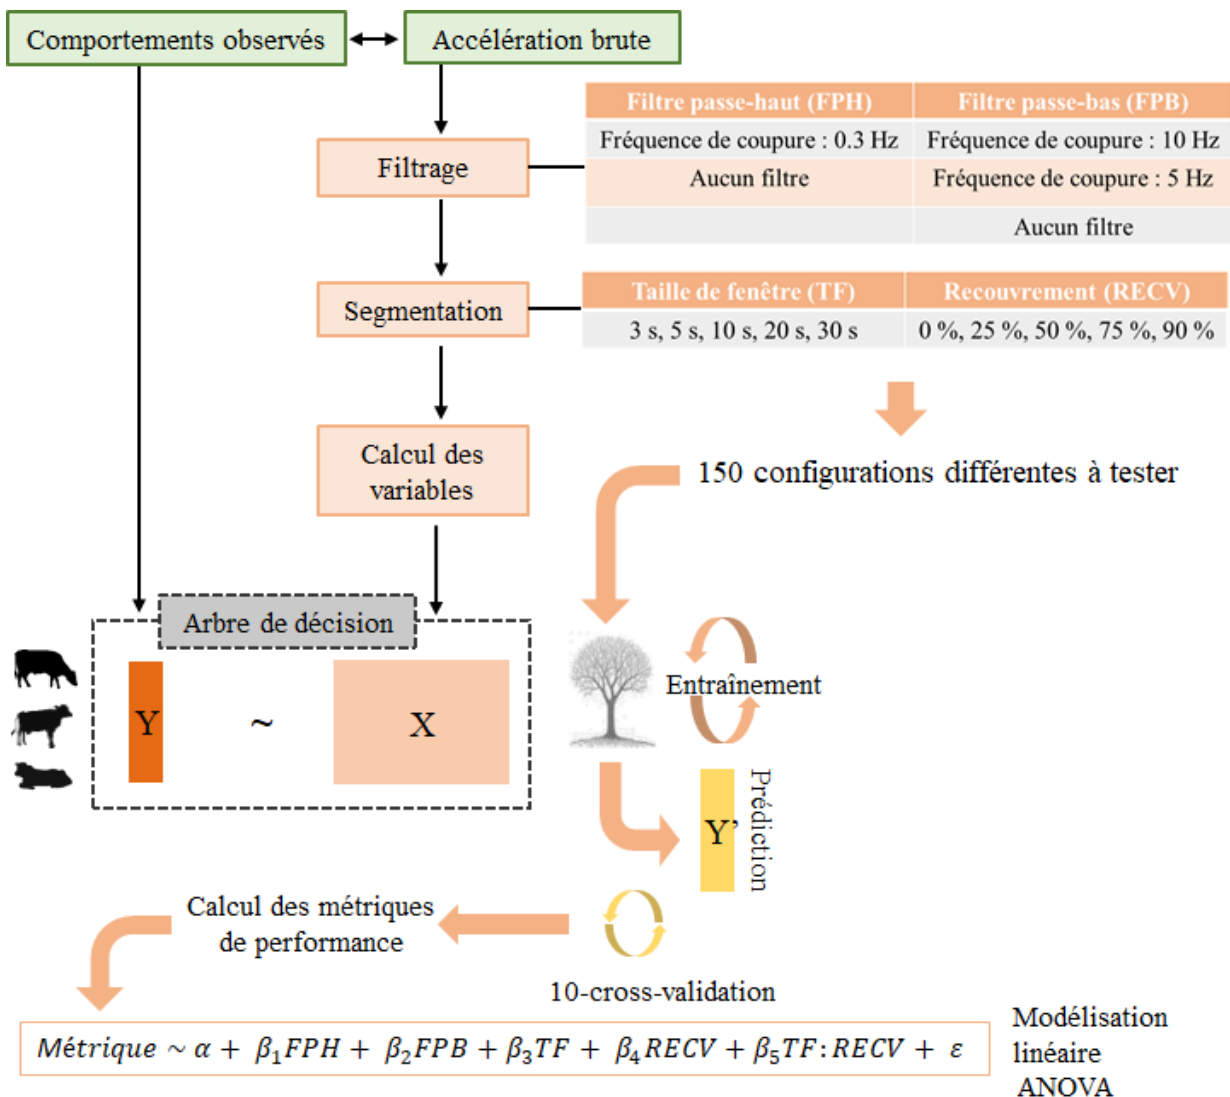


Figure 14. Vue d'ensemble sur la méthodologie proposée pour évaluer l'effet de techniques de filtrage et de la taille de la fenêtre

5. Résultats

Les résultats obtenus confirment l'effet significatif du traitement du signal sur la prédiction des comportements des vaches laitières au pâturage. En particulier, les meilleures configurations aboutissent à un pourcentage de bon classement de 95% alors que seulement 76% des comportements sont bien classés avec les configurations les moins optimales. Les performances sont significativement améliorées lorsque l'accélération statique est conservée dans l'analyse ($P < 0.001$). La réduction du niveau de bruit n'a pas eu d'effet sur la prédiction des comportements, quelle que soit la fréquence de coupure du filtre passe-bas. Le recouvrement entre fenêtres améliore systématiquement la prédiction ($P < 0.001$). Concernant la taille de la fenêtre, de meilleures performances ont été obtenues avec celles supérieures ou égales à 10 s à condition d'y inclure un pourcentage de recouvrement supérieur à 50%. Ce dernier point illustre ainsi l'interaction existante entre les différentes techniques de traitement.

MESSAGE A RETENIR

L'étape consistant à obtenir le jeu de données à partir des données accéléromètres brutes est un moyen d'améliorer la classification des comportements des ruminants, au même titre que le classifieur choisi. Les méthodes à privilégier dépendent des objectifs de l'étude et des données collectées lors de la phase expérimentale. Nous recommandons ainsi d'identifier les méthodes les mieux adaptées à chaque étude dans un travail préliminaire avant d'envisager l'étape de classification des comportements des ruminants.

6. Valorisation

Ce travail a donné lieu à un article accepté dans le journal *Computers and Electronics in Agriculture*.

Riaboff, L., Aubin, S., Bédère, N., Couvreur, S., Madouasse, A., Goumand, E., Chauvin, A., Plantier, G., 2019. Evaluation of pre-processing methods for the prediction of cattle behaviour from accelerometer data. *Comput. Electron. Agric.* 165, 104961. <https://doi.org/10.1016/j.compag.2019.104961>

Références

- Andriamandroso, A.L.H., Lebeau, F., Beckers, Y., Froidmont, E., Dufrasne, I., Heinesch, B., Dumortier, P., Blanchy, G., Blaise, Y., Bindelle, J., 2017. Development of an open-source algorithm based on inertial measurement units (IMU) of a smartphone to detect cattle grass intake and ruminating behaviors 40.
- Barwick, J., Lamb, D.W., Dobos, R., Welch, M., Trotter, M., 2018. Categorising sheep activity using a tri-axial accelerometer. *Comput. Electron. Agric.* 145, 289–297. <https://doi.org/10.1016/j.compag.2018.01.007>
- Benaissa, S., Tuytens, F.A.M., Plets, D., Cattrysse, H., Martens, L., Vandaele, L., Joseph, W., Sonck, B., 2018. Classification of ingestive-related cow behaviours using RumiWatch halter and neck-mounted accelerometers. *Appl. Anim. Behav. Sci.* <https://doi.org/10.1016/j.applanim.2018.12.003>
- Benson, L.C., Clermont, C.A., Osis, S.T., Kobsar, D., Ferber, R., 2018. Classifying running speed conditions using a single wearable sensor: Optimal segmentation and feature extraction methods. *J. Biomech.* 71, 94–99. <https://doi.org/10.1016/j.jbiomech.2018.01.034>
- Bersch, S., Azzi, D., Khusainov, R., Achumba, I., Ries, J., 2014. Sensor Data Acquisition and Processing Parameters for Human Activity Classification. *Sensors* 14, 4239–4270. <https://doi.org/10.3390/s140304239>
- Decandia, M., Giovanetti, V., Molle, G., Acciaro, M., Mameli, M., Cabiddu, A., Cossu, R., Serra, M.G., Manca, C., Rassu, S.P.G., Dimauro, C., 2018. The effect of different time epoch settings on the classification of sheep behaviour using tri-axial accelerometry. *Comput. Electron. Agric.* 154, 112–119. <https://doi.org/10.1016/j.compag.2018.09.002>
- Keogh, E., Chu, S., Hart, D., Pazzani, M., 2001. An online algorithm for segmenting time series, in: *Proceedings 2001 IEEE International Conference on Data Mining*. Presented at the 2001 IEEE International Conference on Data Mining, IEEE Comput. Soc, San Jose, CA, USA, pp. 289–296. <https://doi.org/10.1109/ICDM.2001.989531>
- Kozina, S., Lus̆trek, M., Gams, M., 2011. Dynamic signal segmentation for activity recognition, in: *Proceedings of International Joint Conference on Artificial Intelligence*. Presented at the International Joint Conference on Artificial Intelligence, Barcelona, Spain, pp. 15–22.
- Lush, L., Wilson, R.P., Holton, M.D., Hopkins, P., Marsden, K.A., Chadwick, D.R., King, A.J., 2018. Classification of sheep urination events using accelerometers to aid improved measurements of livestock contributions to nitrous oxide emissions. *Comput. Electron. Agric.* 150, 170–177. <https://doi.org/10.1016/j.compag.2018.04.018>
- Quante, M., Kaplan, E.R., Rueschman, M., Cailier, M., Buxton, O.M., Redline, S., 2015. Practical considerations in using accelerometers to assess physical activity, sedentary behavior, and sleep. *Sleep Health* 1, 275–284. <https://doi.org/10.1016/j.sleh.2015.09.002>
- Robert, B., White, B.J., Renter, D.G., Larson, R.L., 2009. Evaluation of three-dimensional accelerometers to monitor and classify behavior patterns in cattle. *Comput. Electron. Agric.* 67, 80–84.
- Smith, D., Rahman, A., Bishop-Hurley, G.J., Hills, J., Shahriar, S., Henry, D., Rawnsley, R., 2016. Behavior classification of cows fitted with motion collars: Decomposing multi-class classification into a set of binary problems. *Comput. Electron. Agric.* 131, 40–50. <https://doi.org/10.1016/j.compag.2016.10.006>



Evaluation of pre-processing methods for the prediction of cattle behaviour from accelerometer data

L. Riaboff^{a,c,*}, S. Aubin^a, N. Bédère^{b,e}, S. Couvreur^b, A. Madouasse^d, E. Goumand^c, A. Chauvin^d, G. Plantier^a

^a ESEOTech – LAUM, 49000 Angers, France

^b URSE, Ecole Supérieure d'Agricultures, Univ. Bretagne Loire, 49000 Angers, France

^c Terrena Innovation, 44150 Ancenis, France

^d BIOEPAR, INRA, Oniris, 44307 Nantes, France

^e PEGASE, INRA, AGROCAMPUS OUEST, 35590 Saint-Gilles, France

ARTICLE INFO

Keywords:

Accelerometer
Signal pre-processing
Monitoring livestock behaviour
Behaviour classification
Dairy cows

ABSTRACT

Monitoring livestock behaviour can be a useful way to improve farm animal management and to detect individual health events. The use of automated systems that predict several daily behaviours from accelerometer data is growing and studies have often focused on the comparison of datamining classification methods. However, few studies have attempted to evaluate the effect of the step preceding the classification, namely accelerometer signal pre-processing. This study aimed to evaluate the effect of several pre-processing methods on the prediction of dairy cows behaviour from accelerometer data. Ten Holstein cows equipped with a three-dimensional accelerometer fixed on a neck collar were simultaneously observed by two observers. Observed behaviours were predicted with decision tree using pre-processed accelerometer data as inputs. Different procedures were evaluated for each of these following pre-processing steps: signal filtering, signal segmentation and feature calculation. For signal filtering, low-pass filters and high-pass filters were considered. For signal segmentation, various window sizes and percentages of overlap between windows were implemented. Sixty-nine features were computed. This resulted in 150 different combinations of pre-processing steps. For each combination a decision tree model predicting the observed behaviours was trained. The performance of each model to predict the observed behaviours was compared based on accuracy and F-score measures. The relative importance of each pre-processing configuration on the performance of prediction was evaluated with a linear regression model. The best configurations led to an accuracy of 0.95 and a F-score of 0.96 against 0.76 and 0.65 respectively with the worse combinations. The best combinations included a window size of 20 s and 30 s, with an overlap of 90% and no high-pass filter. High-pass filter had the most significant effect on the classification ($P < 0.001$), with a substantial decrease when it was applied. Performance of the classification was also significantly improved when increasing the percentage of overlapping ($P < 0.001$). The decline of the accuracy observed for the window size of 20 s without overlap was prevented when an overlap higher than 50% was applied. This suggested that overlap should be considered when there is not sufficient data available. No impact was found for the low-pass filter. In conclusion, the way of pre-processing the accelerometer signal deserves to be considered in the classification and adapted according to the aim and design of the study.

1. Introduction

Monitoring livestock behaviour can be a useful way to detect health events such as lameness (Chapinal et al., 2009) or breeding events such as oestrus (Kamphuis et al., 2012). Animals can be observed directly but

it is time consuming and labour-intensive (Penning, 1983; Müller and Schrader, 2003). For these reasons, sensors that automatically monitor the behaviour of livestock can be a good solution (Rushen et al., 2012). Technologies based on electric resistance (Ruter et al., 1997) and on pressure sensors (Ruuska et al., 2016) have been used in discriminating

Abbreviations: HPF, high-pass filter; LPH, low-pass filter; WS, window size; POV, percentage of overlap; NORM, normalization; TP, True Positive; FP, False Positive; TN, True Negative; FN, False Negative

* Corresponding author at: Terrena Innovation, 44150, Ancenis, ESEOTech – LAUM, 49000 Angers, France.

E-mail address: lucile.riaboff@eseo.fr (L. Riaboff).

<https://doi.org/10.1016/j.compag.2019.104961>

Received 21 December 2018; Received in revised form 3 July 2019; Accepted 13 August 2019

0168-1699/© 2019 Published by Elsevier B.V.

between grazing and ruminating. Sound recording (Delagarde et al., 1999) have already considered for the analysis of ingestive and ruminating jaw movements. Among the used technologies, a satisfactory prediction of behaviours was obtained based on accelerometer data (Martiskainen et al., 2009).

Two main steps are usually undertaken between the generation of raw data by a sensor and the prediction of actual behaviours (Brown et al., 2013): first the raw data are pre-processed (**pre-processing step**) and then the pre-processed data are used as input for a prediction algorithm (**classification step**).

The aim of the pre-processing step is to process the raw accelerometer data in order to extract features that are used for the prediction of behaviours. As part of pre-processing, a filtering step can be undertaken, whose aim is to remove some data frequencies associated with noise. For instance, a filter that discards high frequencies, called a low-pass filter, helps reduce the noise (Allen et al., 2006; Fida et al., 2015; Benson et al., 2018) and can improve the classification of human activities. A high-pass filter, which removes low frequencies, is often applied to get body acceleration without the influence of gravity (Oshima et al., 2010; Bayat et al., 2014). Then, the signal is segmented, *i.e.* split into different windows of the same size. Different window sizes and types of window can be applied. For instance, segmentation with fixed overlap, where some acceleration data are common between two consecutive windows, is usually applied in human activity recognition as it improves the accuracy of classification (Bersch et al., 2014). This step is followed by the extraction of features which consists in computing several metrics and summary statistics for each window. Features calculation is usually driven by knowledge about accelerometer signal (Martiskainen et al., 2009; Barwick et al., 2018) but an unsupervised representation of features using convolution neural network and autoencoder has already been considered (Rahman et al., 2016; Kasfi et al., 2016).

The aim of the classification step is to predict behaviours by applying an appropriate classifier on the pre-processed data. The classifier is first trained on a subset of all the data (training data) and validated on the remaining data (validation data). The accuracy is evaluated on the validation data, by comparing observed and predicted behaviours. Most of the approaches considered are supervised, with some methods appearing clearly more effective in discriminating behaviours than others (Nathan et al., 2012). A considerable work has also been carried out on the association of different techniques where unsupervised and supervised approaches are combined (Dutta et al., 2015).

In studies on the prediction of human activities from accelerometer data, pre-processing greatly affects the prediction and is widely discussed (Quante et al., 2015). Concerning the monitoring of livestock behaviour, previous studies have mostly focused on the classifier (Martiskainen et al., 2009; Nathan et al., 2012; Pons et al., 2017), certainly because raw data are often unavailable. Some pre-processing methods have been used in livestock monitoring behaviour (Marais et al., 2014) but their impact on the prediction of behaviours has never been evaluated, except for the comparison of different window sizes (Robert et al., 2009; Vázquez Diosdado et al., 2015; Smith et al., 2016). Considering the importance of pre-processing in human activity recognition, an evaluation of different common pre-processing methods on the classification deserves to be investigated.

The aim of this study was to evaluate the effect of commonly used pre-processing methods on the prediction of cattle behaviour. To this end, different parameters for the following pre-processing steps were investigated: filtering (low-pass filter and high-pass filter), window sizes and percentage of overlapping. All possible combinations of pre-processing steps were carried out and decision trees were used to predict observed cow behaviours. Indicators of performance were used to compare the performance. A linear model and an analysis of variance were used to estimate the relative importance of each pre-processing method.

2. Materials and methods

2.1. Animals

The study was conducted in a 71 Holstein (milk yield: 10,000 kg per year) commercial farm in Lion d'Angers, France (N47°36'43.652", O°43'26.631") in July 2017. Cows were milked every day at 9 am and 6 pm. Maize silage supplement (10 kg/day), concentrate supplement (2 kg/day) and hay supplement (5 kg/day) were distributed after each milking. The cows grazed day and night on temporary pasture, sown with a mixture of perennial ryegrass (*Lolium perenne L.*) and white clover (*Trifolium repens L.*). The average parity of the cows was 2.31 ± 1.35 (mean \pm sd). For the experiment, ten dairy cows ranging between 60 and 300 days in milk and representative of the herd in terms of parity were selected.

2.2. Instrumentation

A RF-Track datalogger (RF-Track, Rennes, France) with a LSM9DS1 three-axis accelerometer (STMicroelectronics, Geneva, Switzerland) ± 2 g was used. Data were collected at 59.5 Hz. The accelerometer was powered with two 3.7 V lithium batteries (2.6 Ah). Data were stored on a SD card and downloaded after the experiment. The dataloggers were $98.2 \times 51.60 \times 36.0$ mm in size and weighed 250 g.

2.3. Data collection

2.3.1. Recording of accelerometer signal

The three-axis accelerometer was mounted on a collar and positioned on the right side of the neck as recommended by Smith et al. (2016). Collars were tightly adjusted and a 500 g counterweight was added to prevent them from turning around (Fig. 1). The x-axis detected the down-up direction, the y-axis detected the left-right direction and the z-axis detected the backward-forward direction. The ten cows were fitted with this collar during one day of grazing, from 11 am to 5 pm.

2.3.2. Collecting of observation data

Cow behaviours were recorded by two observers during grazing without familiarization (Agreil and Meuret, 2004). The first observer tracked a single cow continuously during a 15 min period while the second observer tracked another cow during the same period. Each cow was observed sequentially. At the end of the observation period, all the equipped cows were observed by at least one observer. This resulted in five hours of observations available for the 10 cows. The four behaviours recorded are defined according to the ethogram detailed in Table 1. All other observed behaviours than those defined in the ethogram were classified as "Other".




Fig. 1. RF-Track 3-D accelerometer sensor fixed on the collar on the cow. The three coordinate axes of the IMU are displayed.

Table 1
Definition of the different behaviours recorded.

Behaviour	Classification description
Grazing	Grazing or browsing taking frequent bites, without raising the head
Walking	Movement from one location to another without lowering the head at ground level
Lying	Cow is lying down
Standing	Standing still, no movement to another location

2.4. Combination of the observation data and the corresponding sequence of the signal

After data collection, accelerometers and observations were time synchronized to ensure that the direct observations were associated to the correct sequences of accelerometer signal. In this way, a dataset was obtained in which behaviour observations for each cow and for each observer were combined with the appropriate sequence of accelerometer data.

2.5. Data processing

2.5.1. Overview of the data processing

Each step of pre-processing was investigated, namely signal filtering and segmentation. Several methods were explored for each step. For the filtering step, a low-pass filter with 5 Hz and 10 Hz cut-off frequencies, a high-pass filter with 0.3 Hz cut-off frequency and no filtering were considered. Segmentation was addressed with different window sizes (3 s, 5 s, 10 s, 20 s and 30 s) and different percentages of overlap between consecutive windows (0%, 25%, 50%, 75% and 90%). The same 61 features were then finally extracted from the segmented signal. As a result, 150 different datasets representing 150 combinations of pre-processing steps were obtained. For each combination, a decision tree using the pre-processed data as inputs was used to predict the observed behaviours. A decision tree was used to predict observed cow behaviours because this classifier has a low computational load and has already led to a satisfactory prediction of animal behaviours from accelerometer data (Robert et al., 2009; Nathan et al., 2012; Benaissa et al., 2018). An overview of the data processing is shown in Fig. 2. Pre-processing steps, methods and values used are described in detail in the following sections.

2.5.2. Preprocessing steps

All the pre-processing steps were performed in Matlab R2017a software.

2.5.2.1. Accelerometer signal filtering. The aim of the filtering step is to discard some frequencies to work only with particular frequencies of the signal.

A low-pass filter discards the frequencies of the signal that are higher than the chosen cut-off frequency. Hamäläinen et al. (2011) explained that 10 Hz is sufficient to reduce the amount of noise since cows are calm animals. Consequently, a 6-th order low-pass digital Butterworth filter with a cutoff frequency of 10 Hz was considered. As a low-pass filter could also eliminate relevant information in smoothing the signal, a 6-th-order low-pass digital Butterworth filter with a cutoff frequency of 5 Hz was also considered.

High-pass filter removes frequencies lower than the chosen cut-off frequency. A 6-th-order high-pass digital Butterworth filter with a cutoff frequency of 0.3 Hz (Bayat et al., 2014; Smith et al., 2016) was applied to discard the low frequencies, often related to the gravity component of the acceleration.

2.5.2.2. Signal segmentation. Segmentation consists in splitting the accelerometer signal into windows of the same size. In this work, short window sizes of 3 s, 5 s and 10 s, frequently used in animal

behaviour monitoring (Martiskainen et al., 2009; Barwick et al., 2018), were tested. Window sizes of 20 s and 30 s (Smith et al., 2016) were also considered to compare the effect of short and wide window sizes. Sequences of signal and associated behaviour which were shorter than the considered window size were excluded from the dataset. The number of sequences for each behaviour and for each window size is shown in Table 2.

Fixed overlap consists in repeating a fixed percentage of the beginning of the current window at the end of the previous window and the same percentage of the end of the current window at the beginning of the next window (Bersch et al., 2014). For a same window size, the amount of acceleration data in common depends on the chosen percentage of overlap. Five different percentages of overlap were considered: 0%, 25%, 50%, 75% and 90% (Bersch et al., 2014). The segmentation with overlap is illustrated in Fig. 3 for an overlap of 50%.

Consequently, the number of sequences increased with the percentage of overlap, as shown in Table 3 for the window size of 10 s.

2.5.2.3. Extracted features. For each time-window, a set of features was extracted on each axis. The signal magnitude axis (a_{mag}), considered as orientation independent (Fida et al., 2015), was also calculated:

$$a_{mag} = \sqrt{a_x^2 + a_y^2 + a_z^2}$$

where a_x is the acceleration on the X-axis of the accelerometer, a_y the acceleration on the Y-axis and a_z the acceleration on the Z-axis.

Features were extracted from the X-axis, Y-axis, Z-axis and a_{mag} in time and frequency domain. They included position parameters like mean and median and dispersion parameters like variance, standard deviation, minimum, maximum, quartiles and range. The Root Mean Square (Maurer et al., 2006; Bernecker et al., 2012) was computed for each axis. Other features commonly used such as Signal Magnitude Area (Bouten et al., 1997; Barwick et al., 2018), Average Intensity (Barwick et al., 2018) and Movement Variation (Lush et al., 2018; Barwick et al., 2018) were extracted. Skewness and kurtosis extracted in the time domain (Martiskainen et al., 2009; Dutta et al., 2015) were computed and the maximum of the pairwise correlations between each axis was considered (Velink et al., 1996; Figo et al., 2010). Finally, spectral entropy was extracted from the frequency domain (Zaccarelli et al., 2013). The equations for each feature are listed in Table 4. For each preprocessing configuration, 61 features were extracted from each time-window.

2.5.3. Behaviour classification model

One hundred and fifty datasets corresponding to the 150 combinations of pre-processing parameters were evaluated based on their ability to predict the observed cow behaviours. The predictions of cow behaviours were carried out using a single classifier to compare the results. The chosen classifier should be effective for a classification problem with a low computational load because there are 150 models to train. A satisfactory prediction of animal behaviours has already been obtained with a decision tree (Robert et al., 2009; Nathan et al., 2012; Benaissa et al., 2018). This base-level classifier does not required model fitting so the computational load is low. Consequently, a decision tree was used to predict cow behaviours, based on the 61 features and without pruning. Each decision tree was trained with the rpart package (Therneau and Atkinson, 2018) in R 3.4.0 software. The accuracy of each classification was evaluated with several indicators of model performance.

2.6. Comparison of the performance of each classification model

2.6.1. Overview of the evaluation of the performance

In order to identify the most important pre-processing steps and the best parameters, the performance of the 150 models to correctly predict the observed behaviours was evaluated. Indicators of the overall

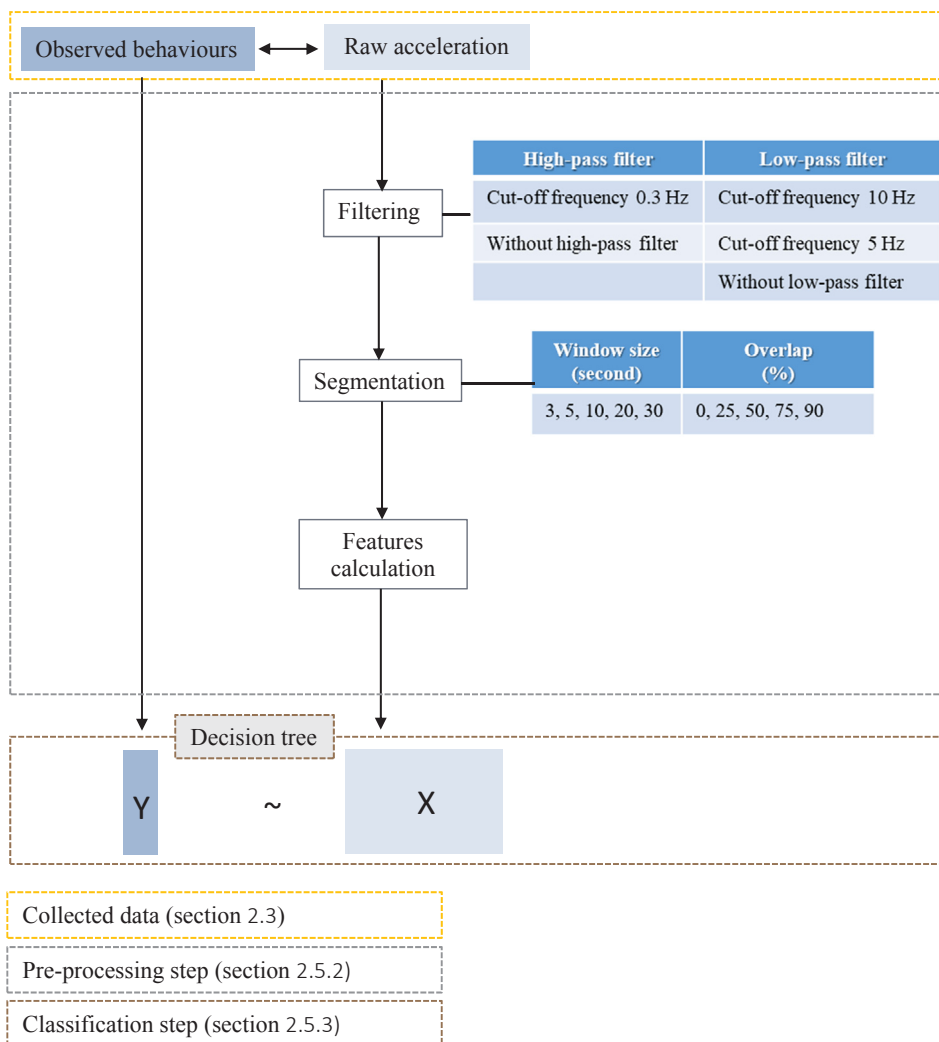


Fig. 2. Overview of data processing.

Table 2

Total number of sequences obtained for each window size and for each behaviour. The number of animals for which behaviour data were collected is shown in parentheses.

Behaviour	Number of sequences for each window size				
	3 s	5 s	10 s	20 s	30 s
Grazing	473 (3)	282 (3)	138 (3)	67 (3)	41 (2)
Walking	192 (3)	113 (3)	54 (3)	24 (3)	14 (3)
Lying	1707 (7)	1021 (7)	508 (7)	252 (7)	166 (7)
Standing	868 (6)	518 (6)	253 (5)	121 (5)	79 (5)

performance of the model, based on a 5-fold cross validation procedure, were computed. An analysis of variance was performed to estimate the effect of each pre-processing method on the performance indicators. The evaluation was also carried out for each behaviour separately, namely “Grazing”, “Standing”, “Lying” and “Walking”, in a supplementary analyse.

(a) Without overlapping



(b) With 50% of overlapping




Fig. 3. Explanation of segmentation with overlap: fixed window without overlap (a) and fixed window with 50% overlap (b).

2.6.2. 5-fold cross-validation procedure

A 5-fold cross-validation procedure was applied to evaluate the performance of each of the 150 obtained models as there were not sufficient data available to evaluate the performance with independent animals in this study. This common procedure consists in training the model with 4/5 of the data (training dataset) and evaluating its predictive performance on the remaining 1/5 (validation dataset). The split was stratified so that the percentage in each behaviour was similar between training dataset and the validation dataset. This procedure was repeated 5 times to ensure that all data were used for prediction. At each iteration, a confusion matrix was obtained and an average confusion matrix was computed at the end of the procedure (Pober et al., 2006). A set of common performance indicators was then computed from the confusion matrix to evaluate the impact of the pre-processing on both the overall accuracy and for each behaviour separately.

2.6.3. Evaluation of the overall performance of each classification model

2.6.3.1. Performance indicators. All performance indicators were computed with the caret package (Kuhn et al., 2018). The evaluation

Table 3

Total number of sequences obtained for each percentage of overlap for the window size of 10 s and for each behaviour. The associated percentage of sequences for each behaviour is shown in brackets. The number of animals for which behaviour data were collected is shown in parentheses.

Behaviour	Number of sequences for each overlap for the window size of 10 s				
	0%	25%	50%	75%	90%
Grazing	138 [14] (3)	183 [14] (3)	271 [14] (3)	537 [14] (3)	1326 [14] (3)
Walking	54 [6] (3)	70 [6] (3)	101 [5] (3)	196 [5] (3)	480 [5] (3)
Lying	508 [53] (7)	675 [53] (7)	1011 [54] (7)	2020 [54] (7)	5008 [54] (7)
Standing	253 [27] (5)	335 [27] (5)	501 [27] (5)	993 [27] (5)	2459 [27] (5)

of the overall performance of each model for the prediction of observed behaviours was based on indicators computed from the confusion matrix. Overall accuracy was computed with Eq. (1):

$$accuracy = \frac{\text{Total number of well classified instances}}{\text{Total number of instances}} \quad (1)$$

The F-score metric (*F*), based on recall (*R*) and precision (*P*) was also calculated at each iteration of the 5-fold cross-validation procedure using Eq. (2):

$$F = \frac{2 \cdot P \cdot R}{P + R} \text{ where } R = \frac{TP}{TP + FN} \text{ and } P = \frac{TP}{TP + FP} \quad (2)$$

where *TP* (True Positives) is the number of instances where the behaviour was observed and correctly predicted; *FN* (False Negatives) is the number of instances where the behaviour was observed but another behaviour was predicted, *FP* (False Positives) is the number of instances where the behaviour was predicted but another behaviour was observed; *TN* (True Negatives) is the number of instances where the behaviour was not observed and not predicted. The F-score metric is the harmonic mean of precision and recall, ranging between 0 and 1. The better the model is performing, the closer the F-score will be to 1. The overall F-score of the model was computed by averaging the 5 F-scores obtained during the 5-fold cross-validation procedure.

2.6.3.2. Evaluation of the preprocessing parameters with a linear model and an analysis of variance. The relation between indicators of predictive performance and pre-processing parameters was evaluated using linear

models which had each indicator as their outcome and the parameter of each pre-processing step as covariates. As an interaction between window size and the percentage of overlap has been shown by Bersch et al. (2014), this interaction was also included, leading to the initial model described with Eq. (3):

$$indicator \sim \alpha + \beta_1 HPF + \beta_2 LPF + \beta_3 WS + \beta_4 POV + \beta_5 WS:POV + \varepsilon \quad (3)$$

where the outcome *indicator* was either accuracy or F-score, defined in Section 2.6.3.1. High-pass filter (*HPF*), low-pass filter (*LPF*), window size (*WS*), percentage overlap (*POV*) and the interaction between window size and percentage of overlap (*WS:POV*) were the explanatory variables. Finally α was the overall mean, β_1, \dots, β_5 were the coefficients to estimate and ε was the residual error.

A backward procedure was adopted to get the final model with only significant parameters. In this procedure, all parameters are considered in the first model which is analysed with an analysis of variance (ANOVA). Then, the parameter which is the less significant is removed from the model. This procedure is repeated until all parameters included in the model are significant. ANOVA of type III was carried out with car package (Fox and Weisberg, 2011) in R 3.4.0 software.

A tuckey test was finally applied on each explicative parameter to identify the levels which are significantly different from each other. The tuckey test was carried out in R 3.4.0 software with the lsmeans package (Lenth, 2016).

Table 4

Equation of the calculated features from the acceleration values.

Feature	Equation
Average X-axis (\bar{A}_x)	$\bar{A}_x = \frac{1}{M} \sum_{i=1}^M a_{xi}$
Variance X-axis (σ_x^2)	$\sigma_x^2 = \frac{1}{M} \sum_{i=1}^M (a_{xi} - \bar{A}_x)^2$
Standard deviation X-axis (σ_x)	$\sigma_x = \sqrt{\sigma_x^2}$
Minimum X-axis (Min_x)	The minimum of the X-axis within the window
Maximum X-axis (Max_x)	The maximum of the X-axis within the window
Range X-axis ($Range_x$)	$Range_x = Max_x - Min_x$
Median X-axis ($Q_{2;x}$)	The median of the X-axis within the window
First Quartile X-axis ($Q_{1;x}$)	The first quartile of the X-axis within the window
Third Quartile X-axis ($Q_{3;x}$)	The third quartile of the X-axis within the window
Interquartile range X-axis (IQ_x)	$IQ_x = Q_{3;x} - Q_{1;x}$
Root Mean Square X-axis (<i>RMS</i>)	$RMS = \sqrt{\frac{1}{M} \sum_{i=1}^M a_{xi}^2}$
Signal Magnitude Area (<i>SMA</i>)	$SMA = \frac{1}{M} (\sum_{i=1}^M a_{xi} + \sum_{i=1}^M a_{yi} + \sum_{i=1}^M a_{zi})$
Average Intensity (<i>AI</i>)	$AI = \frac{1}{M} \sum_{i=1}^M a_{mag}$
Movement Variation (<i>MV</i>)	$MV = \frac{1}{M} (\sum_{i=1}^{M-1} a_{x,i+1} - a_{x,i} + \sum_{i=1}^{M-1} a_{y,i+1} - a_{y,i} + \sum_{i=1}^{M-1} a_{z,i+1} - a_{z,i})$
Skewness X-axis ($\beta_{1;x}$)	$\beta_{1;x} = \frac{1}{M} \sum_{i=1}^M \left(\frac{a_{xi} - \bar{A}_x}{\sigma} \right)^3$
Kurtosis X-axis ($\beta_{2;x}$)	$\beta_{2;x} = \frac{1}{M} \sum_{i=1}^M \left(\frac{a_{xi} - \bar{A}_x}{\sigma} \right)^4$
Maximum of the pairwise correlations X-axis and Y-axis ($Max_corr_{x,y}$)	The maximum of the correlation between the X-axis and Y-axis within the window
Spectral entropy (H_s)	$H_s = - \sum_{k=1}^N P_k \ln(P_k)$ with $P_k = \frac{ l_k ^2}{\sum_i l_i ^2}$ and for the frequency l_k

2.6.4. Evaluation of performance on each behaviour separately

A supplementary analysis was performed to evaluate the pre-processing effect on each behaviour separately. Accuracy, sensitivity and specificity were calculated for each behaviour with the caret package (Kuhn et al., 2018) using Eqs. (4), (5) and (6) respectively:

$$accuracy_i = \frac{\text{Total number of well classified instances}_i}{\text{Total number of instances}_i} \tag{4}$$

$$sensitivity_i = \frac{TP_i}{TP_i + FN_i} \tag{5}$$

$$specificity_i = \frac{TN_i}{FP_i + TN_i} \tag{6}$$

where *i* is the considered behaviour and *TP*, *FN*, *FP* and *TN* were defined in the same way as the previous section. For these results, they were presented as numerical differences and not as statistical differences.

3. Results

3.1. Best and worse combinations of pre-processing methods

Considering the combination of each preprocessing method, 4 out of 150 combinations led to the best performance (accuracy: 0.95; F-score: 0.96). Best combinations included no high-pass filter, a window size of 20 s or 30 s and an overlap of 90%. Every configuration of low-pass filter were included. No combination led to the lowest performance for both indicators jointly (accuracy: 0.76; F-score: 0.65). Three combinations led to the lowest accuracy. Each of these combinations included a high-pass filter, a low-pass filter at 5 Hz, a window size of 3 s with an overlap of 0%, 50% or 75%. A single configuration led to the lowest F-score and included a high-pass filter, no low-pass filter, a window size of 20 s and without overlap.

Table 5
ANOVA results: evaluation of the pre-processing effect on the overall performance.

	Effect	Accuracy		Fscore	
		Significance levels ¹	mean ± sd	Significance levels ¹	mean ± sd
LPF	None	0.82	0.87 ^a ± 0.07	0.30	0.87 ^a ± 0.07
	10 Hz		0.87 ^a ± 0.06		0.87 ^a ± 0.07
	5 Hz		0.87 ^a ± 0.06		0.87 ^a ± 0.07
HPF	None	***	0.92 ^a ± 0.02	***	0.93 ^a ± 0.05
	0.3 Hz		0.82 ^b ± 0.04		0.81 ^b ± 0.05
WS	3	***	0.85 ^a ± 0.08	***	0.83 ^a ± 0.09
	5		0.86 ^a ± 0.07		0.85 ^b ± 0.08
	10		0.87 ^b ± 0.05		0.88 ^c ± 0.06
	20		0.88 ^b ± 0.05		0.89 ^c ± 0.07
	30		0.88 ^b ± 0.05		0.89 ^c ± 0.05
POV	0	***	0.85 ^a ± 0.06	***	0.85 ^a ± 0.08
	25		0.86 ^{ab} ± 0.06		0.86 ^{ab} ± 0.07
	50		0.87 ^{bc} ± 0.06		0.87 ^{abc} ± 0.07
	75		0.88 ^{cd} ± 0.06		0.88 ^{bc} ± 0.07
	90		0.89 ^d ± 0.06		0.89 ^c ± 0.07
WS × POV		***		***	
adjusted R ²		0.89		0.84	

Significant levels: ***P < 0.001; **P < 0.01; *P < 0.05; †P < 0.1.

¹ Effects of high-pass filter (HPF), low-pass filter (LPF), window size (WS), percentage of overlapping (POV), window size * percentage of overlapping (WS × POV).

^{a-d} Distinguish adjusted means that are different for high-pass filter, low-pass filter, window size, percentage of overlapping (P < 0.05, Tukey's pairwise comparison).

3.2. Effect of each preprocessing method on the overall performance of the classification

3.2.1. Effect of the filtering on the classification

No significant effect was found for the low-pass filter, neither for the accuracy nor for the F-score (Table 5).

The accuracy of the classification was reduced when a high-pass filter was used (-0.05; P < 0.001; Table 5). The F-score was also decreased by the use of a high-pass filter (-0.06; P < 0.001; Table 5).

3.2.2. Effect of the segmentation on the classification

3.2.2.1. Evaluation of the window size effect. The accuracy increased with window size until a threshold of 10 s (P < 0.001; Table 5). The window sizes of 3 s and 5 s led to a significantly lower accuracy than with other window sizes (respectively: -0.02; P < 0.001 and -0.01; P < 0.001). The accuracy increased with the window size of 20 s (+0.01; P < 0.001) and 30 s (+0.02; P < 0.001).

The F-score also increased with the window size until a threshold of 10 s (P < 0.001). The F-score was significantly lower when the window size of 3 s (-0.04; P < 0.001) and 5 s were applied (-0.02; P < 0.001). The window sizes of 10 s, 20 s and 30 s led to a higher F-score (respectively: +0.01; P < 0.01; +0.02; P < 0.001 and +0.03; P < 0.001).

3.2.2.2. Evaluation of the overlapping percentage effect. The accuracy increased with the percentage of overlap until 75% (P < 0.001; Table 5). Percentages of 0% and 25% led to a lower accuracy (respectively: -0.02; P < 0.001 and -0.01; P < 0.001). Accuracy was improved when the percentages 75% (+0.01; P < 0.001) and 90% (+0.02; P < 0.001) were applied.

The F-score was also improved with the percentage of overlap until 75% (P < 0.001; Table 5). The F-score was decreased with the percentages of 0% (-0.02; P < 0.001) and 25% (-0.01; P < 0.001). Percentages of 75% and 90% led to the higher F-score (respectively: +0.01; P < 0.001 and +0.02; P < 0.001).

3.2.2.3. Evaluation of the effect of the interaction between window size and overlapping percentage. The effect of the interaction between window




Fig. 4. Interaction effect of percentage overlapping (POV) and window size (WS) on the accuracy (a) and on the F-score (b) (mean \pm 95% IC).

size and percentage of overlap on the accuracy and on the F-score is illustrated in Fig. 4.

The accuracy of the classification increased from the window size of 3 s to 10 s for each overlapping percentage (Fig. 4a). The greater the overlap percentage, the more the rise was substantial. For instance, the increase was +0.04 for 90% of overlap and +0.012 for 0% of overlap (Fig. 4a). From 10 s to 20 s, the accuracy continued to increase, except for the 25% of overlap where a slight decrease was observed (-0.01 ; Fig. 4a). From 20 s to 30 s, the accuracy was improved when the overlaps of 75% (+0.01; Fig. 4a) and 90% were applied (+0.02; Fig. 4a). In contrast, the accuracy decreased with the overlaps of 0% (-0.01 ; Fig. 4a), 25% (-0.01 ; Fig. 4a) and also slightly with 50% of overlap (-0.01 ; Fig. 4a).

The F-score also increased from the window size of 3 s to 10 s for each overlapping percentage (Fig. 4b). The more the overlap percentage was important, the more the F-score was improved. For instance, the increase was +0.06 for 90% of overlap and +0.04 for 0% of overlap (Fig. 4b). From 10 s to 20 s, the accuracy decreased considerably with the overlap of 0% (Fig. 4b; -0.03) and slightly with the overlap of 25% (Fig. 4b; -0.002) but continued to increase with other overlaps. From 20 s to 30 s, the F-score continued to rise with the overlaps 75% (+0.003; Fig. 4b) and 90% (+0.02; Fig. 4b). In contrast, the F-score was reduced with the overlaps of 0% (-0.01 ; Fig. 4b) and 25% (-0.01 ; Fig. 4b). An increase was also observed from 20 s to 30 s with 0% of overlap (+0.01; Fig. 4b) although it was not significant ($P < 0.05$; Tukey's pairwise comparison; data not shown).

3.3. Effect of each preprocessing method on the classification of each behaviour

3.3.1. Effect of filtering on the classification of each behaviour

No impact was found for the low-pass filter (data not shown). All the considered behaviours were better predicted without high-pass filter (Fig. 5). The impact of the high-pass filter was less pronounced for the behaviour "Grazing" than for other behaviours. The sensitivity and accuracy of the behaviour "Walking" were both decreased with the high-pass filter (sensitivity: 0.94 ± 0.04 without high-pass filter; 0.81 ± 0.08 with high-pass filter; accuracy: 0.97 ± 0.02 without high-pass filter; 0.90 ± 0.04 with high-pass filter). All the performance indicators of the behaviour "Lying" were reduced with the high-pass filter and the specificity was the most affected (0.90 ± 0.02 without high-pass filter; 0.77 ± 0.05 with high-pass filter). The prediction of the behaviour "Standing" seemed to be the most impacted by the high-pass filter. The sensitivity was the indicator with the most substantial decrease (0.82 ± 0.03 without high-pass filter; 0.60 ± 0.11 with high-pass filter).

3.3.2. Effect of segmentation on the classification of each behaviour

All the considered behaviours were better predicted with the window sizes of 20 s and 30 s (Fig. 6). The lowest performance was obtained with the window size of 3 s with all behaviours. However, the effect of the window size was slightly different depending on the behaviour. The smallest effect was observed with the behaviours "Grazing" and "Lying". For the behaviour "Walking", only the sensitivity seemed to be affected by the window size (0.83 ± 0.09 with the window size of 3 s; 0.91 ± 0.07 with the window size of 30 s). The same conclusions were drawn with the behaviour "Standing" (sensitivity: 0.65 ± 0.19 with the window size of 3 s; 0.75 ± 0.09 with the window size of 30 s).

The performance of the prediction of each behaviour was systematically improved when the overlapping increased (Fig. 7). However, the effect was different depending on the behaviour. No effect was observed for the behaviour "Grazing". An improvement was noticed for the sensitivity of the behaviour "Walking" (0.86 ± 0.10 with 0% of overlap; 0.89 ± 0.07 with 90% of overlap). All the indicators were increased for the behaviour "Lying" (accuracy: 0.87 ± 0.05 , sensitivity: 0.91 ± 0.04 , specificity: 0.83 ± 0.06 with 0% of overlap; accuracy: 0.90 ± 0.05 , sensitivity: 0.94 ± 0.03 , specificity: 0.85 ± 0.09 with 90% of overlap). The effect of the overlapping percentage was most pronounced for the behaviour "Standing", in particular for the sensitivity (0.69 ± 0.12 with 0% of overlap; 0.73 ± 0.16 with 90% of overlap).

4. Discussion

4.1. Optimal preprocessing combination for the study

In this study, 4 out of 150 combinations of preprocessing parameters led to the best performance for the prediction of cow behaviours with an accuracy of 0.95 and a F-score of 0.96. This performance was better than that found in other similar studies (Martiskainen et al., 2009; Benaissa et al., 2018). The worst performance was obtained with three combinations for the accuracy (0.76) and one for the F-score (0.65). This performance was lowest than those obtained with most of the supervised classifier in other studies (Dutta et al., 2015). This highlights the importance of pre-processing in the prediction of cow behaviours from accelerometer data.

Both best combinations included no high-pass filter, a window size of 20 s and 30 s and an overlap of 90%. These configurations were consistent with the individual effects observed for each pre-processing method. The worse performance for the accuracy included the high-pass filter and the window size of 3 s with overlaps of 0%, 50% and 75%. The lowest F-score was obtained with the window size of 20 s and without overlap. Therefore, the window size of 20 s was included both in the best and worst configurations for the F-score, depending on the applied overlap. This result shows the importance of considering each preprocessing step both separately as well as in combination.

Each pre-processing step and its impact are discussed in the following section.

4.2. Importance of the gravity component

The accuracy, sensitivity and specificity of each behaviour were systematically lower when the high-pass filter was applied. These results are in agreement with Erdaş et al. (2016) where the high-pass filter decreased the accuracy of the classification of human activities.

The use of a high-pass filter in this way leads to discriminate the behaviours only on the basis of the dynamic body acceleration. The static acceleration was not considered, as explained by Brown et al. (2013). However, it is assumed that the dynamic and static components of the acceleration were complementary for the classification of the behaviours. The dynamic component obtained after high-pass filtering provides information on the level of the motion intensity. The gravity

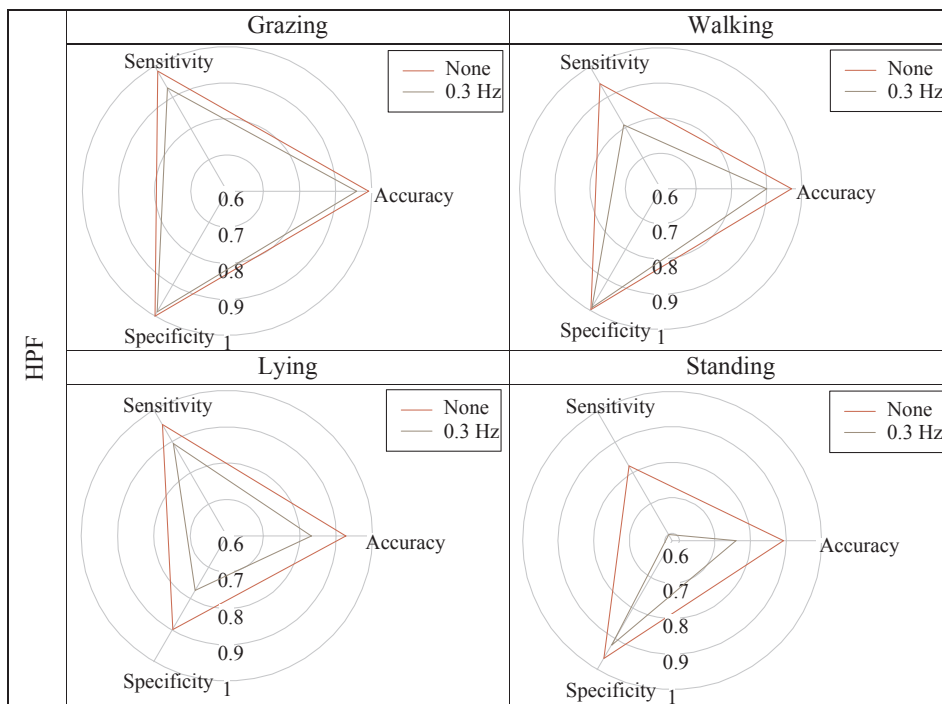


Fig. 5. Influence of the high-pass filter (HPF) on the accuracy, sensitivity and specificity of the classification of the behaviours “Grazing”, “Walking”, “Lying” and “Standing”.

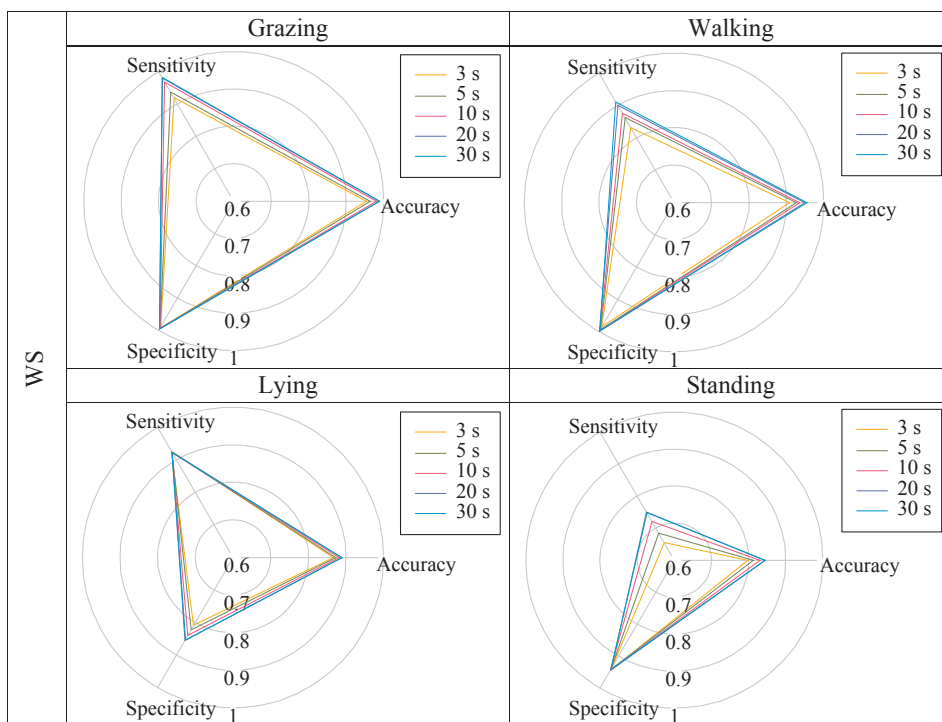


Fig. 6. Influence of the window size (WS) on the accuracy, sensitivity and specificity of the classification of the behaviours “Grazing”, “Walking”, “Lying” and “Standing”.

component, often isolated with a low-pass filter, provides information about the posture of the animal (Karantonis et al., 2006; Oshima et al., 2010). Therefore, the filter process is performed to discriminate activities with different ranges of body acceleration, like walking and resting. In contrast, the gravitational acceleration is used to discriminate static postures such as walking and grazing, where the head is up and down, respectively.

When the purpose is to discriminate behaviours from an ethogram with different static postures, considering only the dynamic acceleration as proposed by Benaissa et al. (2018) does not appear to be the best strategy to adopt. Features can be thus extracted directly from the raw acceleration, as frequently done in similar studies (Robert et al., 2009; Arcidiacono et al., 2017; Abell et al., 2017). Features can also be calculated from the gravity and motion body components separately after

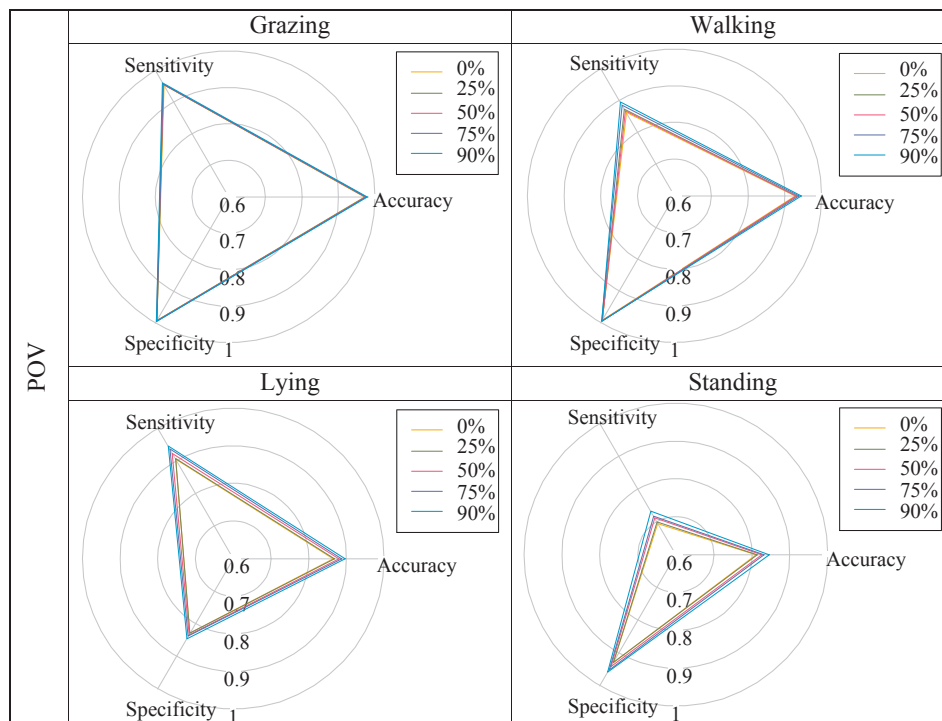


Fig. 7. Influence of the percentage of overlap (POV) on the accuracy, sensitivity and specificity of the classification of the behaviours “Grazing”, “Walking”, “Lying” and “Standing”.

isolating the gravity component (Oshima et al., 2010). Another strategy is to extract features from the body acceleration and to compute orientation time series like pitch and roll to keep information about the posture of the animal (Nadimi et al., 2008; Smith et al., 2016; Lush et al., 2018). As such, it would be efficient to estimate the relative importance of the extracted features to evaluate the importance of both components of the acceleration in the discrimination of each behaviour (Bersch et al., 2014).

It should be noted that the separate body-based acceleration from the gravitational component with high-pass filtering or other similar approaches (Allen et al., 2006; Karantonis et al., 2006) is not always obvious. It is notably the case when the sensor changes its orientation relative to the body during the experiment. Hence, other filters are developed to solve this issue, like the jerk filter (Hamäläinen et al., 2011), and may also improve the performance of the classifier.

4.3. Absence of effect of the noise reduction

The low-pass filter did not impact the performance of the classification, in agreement with Erdaş et al. (2016). However, it is a pre-processing step frequently implemented in human activities recognition to remove some of the noise in the data (Karantonis et al., 2006; Noor et al., 2017; Lee and Kwan, 2018). Sometimes, this step is regarded as indispensable (Peach et al. 2014). Nevertheless, Brown et al. (2013) note that the noise in the accelerometer signal in animal behaviour is mainly induced by the non-rigid attachments of accelerometers collars. In this study, collars were very tight and a counterweight was added to ensure the fixity of the accelerometer. It should be interesting to carry out this study with a loosely-attached accelerometer to evaluate the impact of the low-pass filter in this case. It is sometimes mentioned that tiny movements are recorded in the signal even if the animal doesn't move (Müller and Schrader, 2003). A low-pass filter may have improved the classification in this case.

4.4. Impact of window size and benefits of overlap

The performance of the classification model improved with the increase of the window size until the threshold of 10 s. After this threshold, the performance was similar. This trend is also observed in human activity recognition (Banos et al., 2014) and in livestock activity monitoring (Robert et al., 2009; Andriamandroso et al., 2017). An overlap higher than 50% prevented the decrease of performance observed from 10 s to 20 s, except for the accuracy with 0% of overlap where a non-significant rising was observed. From 20 s to 30 s, accuracy and F-score continued to increase for the overlaps of 75% and 90%. The F-score was also risen from 20 s to 30 s with 0% of overlap but it was probably biased by the high standard deviation observed at the previous point. This compensatory effect of overlapping is exactly the same as those observed by Bersch et al. (2014). As explained by Andriamandroso et al. (2017), the more the window size increases, the more complicated it is to get signal sequences associated with a single observed behaviour. Animals generally performed several activities over a period of more than 20 s therefore wide window sizes lead to a high percentage of unused sequences (Andriamandroso et al., 2017). This suggests that the observed decline of the accuracy above a certain threshold of window size is more linked to the number of sequences used to train the classifier than linked to the size of the window itself (Moreau et al., 2009). For this reason, the segmentation with overlap, which increases the number of sequences used, is an interesting way to improve the classification. As explained by Bersch et al. (2014) and Bayat et al. (2014), overlap is also a relevant way to better predict short transitory behaviours, like “stand up” or “lying down”.

Segmentation with fixed overlap systematically improves the performance of the classification (Bersch et al., 2014; Lee and Kwan, 2018) and is easy to implement, explaining certainly why this method is widely used in human activity recognition (Bao and Intille, 2004; Preece et al. 2009; Benson et al., 2018). In animal behaviour monitoring, it has only been used in few studies (Marais et al., 2014). Therefore overlap implementation is certainly a way to improve the prediction of animal behaviour from accelerometer data. Concerning

the window size, there is not a unique best window size to suggest, as it depends on several parameters such as the number of sequences, the sampling rate, the location of the sensor and the specific behaviours to detect (Robert et al. 2009; Alvarenga et al., 2016; Andriamandroso et al., 2017). Consequently, authors suggest adapting the window size to the objective and to the experimental design. Several window sizes can also be tested in a preliminary study to find the best window size to adopt in each specific study.

The segmentation methods considered in this study were not exhaustive and other promising segmentation methods could also be tested. For instance, a fixed window size was chosen in this study but an adaptive sliding window (Noor et al., 2017) could improve the results of the classification. This type of window is however less easy to implement.

4.5. Perspective: Towards practical application in farming

4.5.1. Adaptation of the pre-processing configuration to the final application

This study showed that some configurations of pre-processing lead to a better prediction than others but this step should also be adapted to the final application of the sensor. First, the behaviours to predict should be considered. Concerning filtering, it can be relevant to apply high-pass filtering to work only with the dynamic body acceleration if the target of the study is to discriminate the activities among the motion intensity. In this context, Shahrir et al. (2016) computed features on the high-pass filtered signal to discriminate three levels of motion intensity. Then, they used these three levels of activity to detect oestrus (period of sexual behaviours) in dairy cows. A high-pass filter can also be used as a first step of classification, as proposed by Barker et al. (2018). They high-pass filtered the signal to discriminate “high activity” and “low activity” in the first step and then used location to discriminate the final behaviours. The size of windows should also be adapted to the behaviours to predict. De Weerd et al. (2015) and Smith et al. (2016) explained that several behaviours can be carried out during wide window sizes, in particular if short behaviours are considered. It can be problematic for the application in farming as the classifier was not trained to predict windows with several behaviours. In this study, the prediction was not significantly better with window sizes wider than 10 s, as in other similar studies (Gonzalez et al., 2015). Thus, segmenting with windows wider than 10 s is not necessarily the best choice to adopt, in particular if the target is to predict short events, like walking, standing up or lying down.

Some authors focused on reducing the computational load as the on-cow sensors used for behaviour have very small batteries with low processing and storage capabilities (Benaissa et al., 2018). For this purpose, the pre-processing could also be adapted. For instance, overlap improves the prediction but increases the number of sequences to analyse so the computational load to extract features and train the classifier may be also raised (Bersch et al., 2014). The percentage of overlap can be adapted to find a fair compromise between the performance of the prediction and the computational load. Another way to decrease the storage of accelerometer data is to decrease the sampling rate. This aspect of pre-processing was not investigated in this study but it would be interesting to down-sample the signal and to evaluate the impact on the performance, as proposed by Benaissa et al. (2017).

4.5.2. Prediction with an appropriate classifier

As the aim of this study was not an optimization problem and there were 150 models to train, a decision tree was applied to predict cow behaviours. Some algorithms like Random Forest or Support Vector Machine perform better than decision trees (Nathan et al., 2012) but a step of model fitting is required before prediction. Model fitting consists in testing several values for each parameter and evaluating the prediction of each model to keep the most effective. Thus, this step is time-consuming, in particular if there are many datasets to consider. This is

the reason why the decision tree was chosen for this study. However, in a context of optimization for an application in farming, the prediction deserves to be evaluated with several classifiers. If other classifiers were applied like Support Vector Machine, authors also suggest to consider features normalization in the pre-processing parameters. Indeed, features normalization was not evaluated in this study because the decision trees are not influenced by the normalization but it may improve the prediction for most classifiers.

4.5.3. Validation of the model of prediction

A cross-validation was used to evaluate the models. Samples from the same animal become part of training and test set in this procedure, in particular if overlap between windows is applied. As observed by Rahman et al. (2018) with a leave-out-of-animal approach, the high variability between animals can induce a drop of performance when the model is applied with other animals. Consequently, a leave-out-of-animal approach would be more suitable to evaluate the genericity of the models. However, there were not sufficient data available to evaluate the performance with independent animals in this study. Furthermore, the aim of this study was to compare several pre-processing configurations based on a single method of evaluation of performance, and not to evaluate the genericity of the models. For an application in farming, it is however necessary to ensure that the performance are not substantially decreased when the prediction is carried out with data from new animals.

5. Conclusion

This study aimed to evaluate the effect of different approaches commonly used to pre-process three-dimensional accelerometer data on the prediction of the main behaviours of dairy cows. In this way, several pre-process configurations were considered and evaluated with a single classifier. The best configurations were obtained without high-pass filter, with window sizes of 20 s and 30 s and with an overlap of 90%. Low-pass filter did not affect the classification in this study. These configurations were consistent with the individual effects observed for each pre-processing step taken separately. However, the window size of 20 s was also included in the worst configuration for the F-score, depending on the applied overlap. This result shows the importance to consider each preprocess method separately but also the combination of each of them.

The decision about whether to use a high-pass filter should be adapted to the main target of the study and to the specific behaviours to discriminate. Authors suggest applying an overlap as it improves the prediction of behaviours. In particular, overlap is strongly recommended if there is not enough sequences for one or several behaviours. The percentage of overlap can however be adapted if the computational load should be reduced. It is more complicated to recommend a window size as it is target and experimental design-dependent. However, we suggest trying several window sizes in a preliminary study to find the best window size for the specific study.

In any cases, this study should be carried out with several datasets to confirm these results. Other classifiers should also be tested in a context of optimization for a concrete application in farming. The combination of the optimal pre-processing configuration with an effective algorithm of classification may solve the problem of the genericity of the model which remains a main challenge in monitoring of livestock behaviour based on accelerometer sensors.

Declaration of Competing Interest

None.

Acknowledgments

We would like to thank the GAEC Beloin (Lion d'Angers, France)

where the experiment took place and Jacques Magnier for his assistance in data collection.

Funding source

This study was funded by Terrena Innovation and the region of Pays-de-la-Loire (France).

References

- Abell, K.M., Theurer, M.E., Larson, R.L., White, B.J., Hardin, D.K., Randle, R.F., 2017. Predicting bull behavior events in a multiple-sire pasture with video analysis, accelerometers, and classification algorithms. *Comput. Electron. Agric.* 136, 221–227. <https://doi.org/10.1016/j.compag.2017.01.030>.
- Agreil, C., Meuret, M., 2004. An improved method for quantifying intake rate and ingestive behaviour of ruminants in diverse and variable habitats using direct observation. *Small Rumin. Res.* 54, 99–113.
- Allen, F.R., Ambikairajah, E., Lovell, N.H., Celler, B.G., 2006. An Adapted Gaussian Mixture Model Approach to Accelerometry-Based Movement Classification Using Time-Domain Features, 4.
- Alvarenga, F.A.P., Borges, I., Palkovič, L., Rodina, J., Oddy, V.H., Dobos, R.C., 2016. Using a three-axis accelerometer to identify and classify sheep behaviour at pasture. *Appl. Anim. Behav. Sci.* 181, 91–99. <https://doi.org/10.1016/j.applanim.2016.05.026>.
- Andriamandroso, A.L.H., Lebeau, F., Beckers, Y., Froimont, E., Dufraes, I., Heinesch, B., Dumortier, P., Blanchy, G., Blaise, Y., Bindelle, J., 2017. Development of an open-source algorithm based on inertial measurement units (IMU) of a smartphone to detect cattle grass intake and ruminating behaviors. *Comput. Electron. Agric.* 139, 126–137. <https://doi.org/10.1016/j.compag.2017.05.020>.
- Arcidiacono, C., Porto, S.M.C., Mancino, M., Cascone, G., 2017. Development of a threshold-based classifier for real-time recognition of cow feeding and standing behavioural activities from accelerometer data. *Comput. Electron. Agric.* 134, 124–134. <https://doi.org/10.1016/j.compag.2017.01.021>.
- Banos, O., Galvez, J.-M., Damas, M., Pomares, H., Rojas, I., 2014. Window size impact in human activity recognition. *Sensors* 14, 6474–6499. <https://doi.org/10.3390/s140406474>.
- Bao, L., Intille, S.S., 2004. Activity recognition from user-annotated acceleration data. In: Ferscha, A., Mattern, F. (Eds.), *Pervasive Computing*. Springer Berlin Heidelberg, Berlin, Heidelberg, pp. 1–17.
- Barker, Z.E., Vázquez Diosdado, J.A., Codling, E.A., Bell, N.J., Hodges, H.R., Croft, D.P., Amory, J.R., 2018. Use of novel sensors combining local positioning and acceleration to measure feeding behavior differences associated with lameness in dairy cattle. *J. Dairy Sci.* 101, 6310–6321. <https://doi.org/10.3168/jds.2016-12172>.
- Barwick, J., Lamb, D.W., Dobos, R., Welch, M., Trotter, M., 2018. Categorising sheep activity using a tri-axial accelerometer. *Comput. Electron. Agric.* 145, 289–297. <https://doi.org/10.1016/j.compag.2018.01.007>.
- Bayat, A., Pomplun, M., Tran, D.A., 2014. A study on human activity recognition using accelerometer data from smartphones. *Proc. Comput. Sci.* 34, 450–457. <https://doi.org/10.1016/j.procs.2014.07.009>.
- Benaissa, S., Tuytens, F.A.M., Plets, D., de Pessemier, T., Trogh, J., Tanghe, E., Martens, L., Vandaele, L., Van Nuffel, A., Joseph, W., Sonck, B., 2017. On the use of on-cow accelerometers for the classification of behaviours in dairy barns. *Res. Vet. Sci.* <https://doi.org/10.1016/j.rvsc.2017.10.005>.
- Benaissa, S., Tuytens, F.A.M., Plets, D., Cattrysse, H., Martens, L., Vandaele, L., Joseph, W., Sonck, B., 2018. Classification of ingestive-related cow behaviours using RumiWatch halter and neck-mounted accelerometers. *Appl. Anim. Behav. Sci.*
- Benson, L.C., Clermont, C.A., Osis, S.T., Kobsar, D., Ferber, R., 2018. Classifying running speed conditions using a single wearable sensor: optimal segmentation and feature extraction methods. *J. Biomech.* 71, 94–99. <https://doi.org/10.1016/j.jbiomech.2018.01.034>.
- Bernecker, T., Graf, F., Kriegel, H.-P., Moennig, C., Dill, D., Tuermer, C., 2012. Activity recognition on 3d accelerometer data (technical report).
- Bersch, S., Azzi, D., Khusainov, R., Achumba, I., Ries, J., 2014. Sensor data acquisition and processing parameters for human activity classification. *Sensors* 14, 4239–4270. <https://doi.org/10.3390/s140304239>.
- Bouten, C.V.C., Koekoek, K.T.M., Verduin, M., Kodde, R., Janssen, J.D., 1997. A triaxial accelerometer and portable data processing unit for the assessment of daily physical activity. *IEEE Trans. Biomed. Eng.* 44, 136–147. <https://doi.org/10.1109/10.554760>.
- Brown, D.D., Kays, R., Wikelski, M., Wilson, R., Klimley, A.P., 2013. Observing the unwatchable through acceleration logging of animal behavior. *Anim. Biotelemetry*.
- Chapinal, N., de Passillé, A.M., Weary, D.M., von Keyserlingk, A.G., Rushen, J., 2009. Using gait score, walking speed, and lying behavior to detect hoof lesions in dairy cows. *J. Dairy Sci.* <https://doi.org/10.3168/jds.2009-2115>.
- Delagarde, R., Caudal, J.-P., Peyraud, J.-L., 1999. Development of an automatic bitometer for grazing cattle. *Ann. Zootech.* 48, 329–339. <https://doi.org/10.1051/animres:19990501>.
- Dutta, R., Smith, D., Rawnsley, R., Bishop-Hurley, G., Hills, J., Timms, G., Henry, D., 2015. Dynamic cattle behavioural classification using supervised ensemble classifiers. *Comput. Electron. Agric.* 18–28. <https://doi.org/10.1016/j.compag.2014.12.002>.
- Erdaş, Ç.B., Atasoy, I., Açııcı, K., Oğul, H., 2016. Integrating features for accelerometer-based activity recognition. *Proc. Comput. Sci.* 98, 522–527. <https://doi.org/10.1016/j.procs.2016.09.070>.
- Fida, B., Bernabucci, I., Bibbo, D., Conforto, S., Schmid, M., 2015. Pre-processing effect on the accuracy of event-based activity segmentation and classification through inertial sensors. *Sensors* 15, 23095–23109. <https://doi.org/10.3390/s150923095>.
- Figo, D., Diniz, P.C., Ferreira, D.R., Cardoso, J.M.P., 2010. Preprocessing techniques for context recognition from accelerometer data. *Pers. Ubiquitous Comput.* 14, 645–662. <https://doi.org/10.1007/s00779-010-0293-9>.
- Fox, J., Weisberg, S., 2011. *An R Companion to Applied Regression*, second ed. Sage, Thousand Oaks CA.
- Gonzalez, L.A., Bishop-Hurley, G.J., Handcock, R.N., Crossman, C., 2015. Behavioral classification of data from collars containing motion sensors in grazing cattle. *Comput. Electron. Agric.* 91–102. <https://doi.org/10.1016/j.compag.2014.10.018>.
- Hamäläinen, W., Järvinen, M., Martiskainen, P., Mononen, J., 2011. Jerk-based feature extraction for robust activity recognition from acceleration data. In: *Intelligent Systems Design and Applications (ISDA)*, 2011 11th International Conference On. IEEE, pp. 831–836.
- Kamphuis, C., DelaRue, B., Burke, C.R., Jago, J., 2012. Field evaluation of 2 collar-mounted activity meters for detecting cows in estrus on a large pasture-grazed dairy farm. *J. Dairy Sci.* 95, 3045–3056. <https://doi.org/10.3168/jds.2011-4934>.
- Karantonis, D.M., Narayanan, M.R., Mathie, M., Lovell, N.H., Celler, B.G., 2006. Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring. *IEEE Trans. Inf. Technol. Biomed.* 10, 156–167. <https://doi.org/10.1109/TITB.2005.856864>.
- Kasfi, K.T., Hellicar, A., Rahman, A., 2016. Convolutional neural network for time series cattle behaviour classification. In: Hellicar, Andrew, Rahman, Ashfaqur, Koch, Fernando (Eds.), *Proceedings of the Workshop on Time Series Analytics and Applications (TSA '16)*. ACM, New York, NY, USA, pp. 8–12.
- Kuhn, M., Wing, J., Weston, S., Williams, A., Keefer, C., Engelhardt, A., Cooper, T., Mayer, Z., Kenkel, B., Benesty, M., Lescarbeau, R., Ziem, A., Scrucca, L., Tang, Y., Candan, C. and Hunt, T., 2018. caret: Classification and Regression Training. R package version 6.0-81. <https://CRAN.R-project.org/package=caret>.
- Lee, K., Kwan, M.-P., 2018. Physical activity classification in free-living conditions using smartphone accelerometer data and exploration of predicted results. *Comput. Environ. Urban Syst.* 67, 124–131. <https://doi.org/10.1016/j.compenvurbys.2017.09.012>.
- Lenth, R.V., 2016. Least-squares means: the R package lsmeans. *J. Statist. Software* 69 (1), 1–33. <https://doi.org/10.18637/jss.v069.i01>.
- Lush, L., Wilson, R.P., Holton, M.D., Hopkins, P., Marsden, K.A., Chadwick, D.R., King, A.J., 2018. Classification of sheep urination events using accelerometers to aid improved measurements of livestock contributions to nitrous oxide emissions. *Comput. Electron. Agric.* 150, 170–177. <https://doi.org/10.1016/j.compag.2018.04.018>.
- Marais, J., Roux, S.P.L., Wolhuter, R., Niesler, T., 2014. Automatic classification of sheep behaviour using 3-axis accelerometer data, 6.
- Martiskainen, P., Järvinen, M., Skön, J.P., Tiirikainen, J., Kolehmainen, M., Mononen, J., 2009. Cow behaviour pattern recognition using a three-dimensional accelerometer and support vector machines. *Appl. Anim. Behav. Sci.* 119, 32–38.
- Maurer, U., Smailagic, A., Siewiorek, D.P., Deisher, M., 2006. Activity recognition and monitoring using multiple sensors on different body positions. In: *International Workshop on Wearable and Implantable Body Sensor Networks (BSN'06)*. Presented at the International Workshop on Wearable and Implantable Body Sensor Networks (BSN'06). IEEE, Cambridge, MA, USA, pp. 113–116.
- Moreau, M., Siebert, S., Buerkert, A., Schlecht, E., 2009. Use of a tri-axial accelerometer for automated recording and classification of goats' grazing behaviour. *Appl. Anim. Behav. Sci.* 119, 158–170. <https://doi.org/10.1016/j.applanim.2009.04.008>.
- Müller, R., Schrader, L., 2003. A new method to measure behavioural activity levels in dairy cows. *Appl. Anim. Behav. Sci.* 83, 247–258. [https://doi.org/10.1016/S0168-1591\(03\)00141-2](https://doi.org/10.1016/S0168-1591(03)00141-2).
- Nadimi, E.S., Søgaard, H.T., Bak, T., 2008. ZigBee-based wireless sensor networks for classifying the behaviour of a herd of animals using classification trees. *Biosyst. Eng.* 100, 167–176. <https://doi.org/10.1016/j.biosystemseng.2008.03.003>.
- Nathan, R., Spiegel, O., Fortmann-Roe, S., Harel, R., Wikelski, M., Getz, W.M., 2012. Using tri-axial acceleration data to identify behavioral modes of free-ranging animals: general concepts and tools illustrated for griffon vultures. *J. Exp. Biol.* 986–996. <https://doi.org/10.1242/jeb.058602>.
- Noor, M.H.M., Salic, Z., Wang, K.I.-K., 2017. Adaptive sliding window segmentation for physical activity recognition using a single tri-axial accelerometer. *Pervasive Mob. Comput.* 38, 41–59. <https://doi.org/10.1016/j.pmcj.2016.09.009>.
- Oshima, Y., Kawaguchi, K., Tanaka, S., Ohkawara, K., Hikihara, Y., Ishikawa-Takata, K., Tabata, I., 2010. Classifying household and locomotive activities using a triaxial accelerometer. *Gait Posture* 31, 370–374. <https://doi.org/10.1016/j.gaitpost.2010.01.005>.
- Peach, D., Van Hoomissen, J., Callender, H.L., 2014. Exploring the ActiLife® filtration algorithm: converting raw acceleration data to counts. *Physiol. Meas.* 35, 2359–2367. <https://doi.org/10.1088/0967-3334/35/12/2359>.
- Penning, P.D., 1983. A technique to record automatically some aspects of grazing and ruminating behaviour in sheep. *Grass Forage Sci.* 38, 89–96. <https://doi.org/10.1111/j.1365-2494.1983.tb01626.x>.
- Pober, D.M., Staudenmayer, J., Raphael, C., Freedson, P.S., 2006. Development of novel techniques to classify physical activity mode using accelerometers. *Med. Sci. Assessing machine learning classifiers for the detection of animals' behavior using depth-based tracking*. *Expert Syst. Appl.* 86, 235–246. <https://doi.org/10.1016/j.eswa.2017.05.063>.
- Pons, P., Jaen, J., Catala, A., 2017. Assessing machine learning classifiers for the detection of animals' behavior using depth-based tracking. *Expert Syst. Appl.* 86, 235–246. <https://doi.org/10.1016/j.eswa.2017.05.063>.
- Preece, S.J., Goulermas, J.Y., Kenney, L.P.J., Howard, D., 2009. A comparison of feature

- extraction methods for the classification of dynamic activities from accelerometer data. *IEEE Trans. Biomed. Eng.* 56, 871–879. <https://doi.org/10.1109/TBME.2008.2006190>.
- Quante, M., Kaplan, E.R., Rueschman, M., Cailler, M., Buxton, O.M., Redline, S., 2015. Practical considerations in using accelerometers to assess physical activity, sedentary behavior, and sleep. *Sleep Health* 1, 275–284. <https://doi.org/10.1016/j.sleh.2015.09.002>.
- Rahman, A., Smith, D., Hills, J., Bishop-Hurley, G., Henry, D., Rawnsley, R., 2016. A comparison of autoencoder and statistical features for cattle behaviour classification. In: Presented at the International Joint Conference on Neural Networks (IJCNN). Vancouver, BC, pp. 2954–2960.
- Rahman, A., Smith, D.V., Little, B., Ingham, A.B., Greenwood, P.L., Bishop-Hurley, G.J., 2018. Cattle behaviour classification from collar, halter, and ear tag sensors. *Inf. Process. Agric.* 5, 124–133. <https://doi.org/10.1016/j.inpa.2017.10.001>.
- Robert, B., White, B.J., Renter, D.G., Larson, R.L., 2009. Evaluation of three-dimensional accelerometers to monitor and classify behavior patterns in cattle. *Comput. Electron. Agric.* 67, 80–84.
- Rushen, J., Chapinal, N., de Passillé, A., 2012. Automated monitoring of behavioural-based animal welfare indicators. *Anim. Welf.* 21, 339–350. <https://doi.org/10.7120/09627286.21.3.339>.
- Ruter, S.M., Champion, R.A., Penning, P.D., 1997. An automatic system to record foraging behaviour in free-ranging ruminants. *Appl. Anim. Behav. Sci.* 54, 185–195. [https://doi.org/10.1016/S0168-1591\(96\)01191-4](https://doi.org/10.1016/S0168-1591(96)01191-4).
- Ruuska, S., Kajava, S., Mughal, M., Zehner, N., Mononen, J., 2016. Validation of a pressure sensor-based system for measuring eating, rumination and drinking behaviour of dairy cattle. *Appl. Anim. Behav. Sci.* 174, 19–23. <https://doi.org/10.1016/j.applanim.2015.11.005>.
- Shahriar, M.S., Smith, D., Rahman, A., Freeman, M., Hills, J., Rawnsley, R., Henry, D., Bishop-Hurley, G., 2016. Detecting heat events in dairy cows using accelerometers and unsupervised learning. *Comput. Electron. Agric.* 128, 20–26. <https://doi.org/10.1016/j.compag.2016.08.009>.
- Smith, D., Rahman, A., Bishop-Hurley, G.J., Hills, J., Shahriar, S., Henry, D., Rawnsley, R., 2016. Behavior classification of cows fitted with motion collars: decomposing multi-class classification into a set of binary problems. *Comput. Electron. Agric.* 131, 40–50. <https://doi.org/10.1016/j.compag.2016.10.006>.
- Therneau, T., Atkinson, B., 2018. rpart: Recursive Partitioning and Regression Tree. R package version 4.1-13. <https://CRAN.R-project.org/package=rpart>.
- Vázquez Diosdado, J.A., Barker, Z.E., Hodges, H.R., Amory, J.R., Croft, D.P., Bell, N.J., Codling, E.A., 2015. Classification of behaviour in housed dairy cows using an accelerometer-based activity monitoring system. *Anim. Biotelemetry* 3. <https://doi.org/10.1186/s40317-015-0045-8>.
- Veltink, P.H., Bussmann, H.J., de Vries, W., Martens, W.J., Van Lummel, R.C., 1996. Detection of static and dynamic activities using uniaxial accelerometers. *IEEE Trans. Rehabil. Eng.* 4, 375–385. <https://doi.org/10.1109/86.547939>.
- de Weerd, N., van Langevelde, F., van Oeveren, H., Nolet, B.A., Kölzsch, A., Prins, H.H., de Boer, W.F., 2015. Deriving animal behaviour from high-frequency GPS: tracking cows in open and forested habitat. *Plos One* 17. <https://doi.org/10.1371/journal.pone.0129030>.
- Zaccarelli, N., Li, B.-L., Petrosillo, I., Zurlini, G., 2013. Order and disorder in ecological time-series: introducing normalized spectral entropy. *Ecol. Indic.* 28, 22–30. <https://doi.org/10.1016/j.ecolind.2011.07.008>.

Chapitre 4 : Développement d'un cadre méthodologique assurant une prédiction robuste des comportements principaux des vaches laitières au pâturage, au moyen d'une combinaison d'algorithmes de *machine learning* sur des données accéléromètres.

1. Contexte de l'étude

L'étude précédente a permis de mettre en évidence les techniques de traitement du signal à privilégier. Il convient de s'intéresser désormais au modèle de classification (Figure 13) en vue d'obtenir une prédiction robuste pour l'ensemble des comportements principaux des vaches laitières au pâturage, ce qui n'est pas le cas de l'existant (Dutta et al., 2015; Rushen et al., 2012). A ce propos, une prédiction satisfaisante des comportements d'ingestion au pâturage, de rumination et de repos a déjà été obtenue avec des méthodes de ML à partir d'un capteur positionné au cou de l'animal (Dutta et al., 2015; Smith et al., 2016). En particulier, les excellentes performances de l'algorithme SVM ont été soulignées dans plusieurs études (Benaissa et al., 2018; Smith et al., 2016; Vázquez Diosdado et al., 2015). Les méthodes ensemblistes de *bagging* (Lush et al., 2018; Smith et al., 2016) et de *boosting* (Dutta et al., 2015) basées sur des arbres de décision ou des analyses linéaires discriminantes conduisent aussi à de très bons résultats. A noter que d'autres méthodes ensemblistes non abordées dans la communauté affichent également d'excellentes performances dans des domaines connexes. C'est notamment le cas de l'algorithme d'eXtreme Gradient Boosting (XGB) qui fait l'objet d'un réel engouement dans une diversité de domaines (Ayumi, 2016; Babajide Mustapha and Saeed, 2016; Shi et al., 2019).

Classifier le comportement de marche (Martiskainen et al., 2009; Smith et al., 2016) et surtout les postures des animaux à partir d'un accéléromètre fixé à un collier semble en revanche beaucoup plus compliqué avec des algorithmes de ML (Martiskainen et al., 2009). Hamäläinen et al. (2011) expliquent à ce propos que les postures « couché » et « debout » correspondent à un niveau d'activité et à un port de tête similaire ce qui ne permet pas de les discriminer correctement avec un accéléromètre au niveau du cou. A ce propos, ces mêmes auteurs suggèrent d'utiliser un modèle de Markov Caché (HMM) pour classifier ces deux postures afin de prendre en compte la structure temporelle au sein d'une séquence de comportements. Les

Chapitre 4

performances obtenues avec le modèle HMM sont néanmoins inférieures à celles obtenues avec des méthodes de ML (Vázquez Diosdado et al., 2015). A ce titre, un lissage des comportements prédits par des modèles de ML *via* l'algorithme de Viterbi basé sur un HMM constitue certainement une alternative intéressante, comme proposé par Yang (2009) en reconnaissance d'activités humaines.

Enfin, la validité des algorithmes au niveau de la période et de l'individu pose des difficultés à la communauté (Moreau et al., 2009; Rahman et al., 2018). Il est probable que les mouvements physiques d'un même animal associés à un même comportement ne soient pas rigoureusement les mêmes selon la période d'expression. D'un animal à l'autre, les mouvements physiques réalisés pour un même comportement ne sont pas non plus identiques (Arcidiacono et al., 2017). Les *patterns* du signal accéléromètre peuvent donc être sensiblement différents d'une période à l'autre et d'une vache à l'autre pour un même comportement, compromettant la robustesse des modèles.

2. Objectifs

L'objectif de cette étude est de proposer un cadre méthodologique qui garantisse une prédiction satisfaisante de l'ensemble des comportements principaux des vaches laitières au pâturage et qui maintienne d'excellentes performances quelles que soit la période d'observation des animaux.

3. Stratégie

Cette étude consiste (1) à mettre en œuvre un traitement du signal adapté, basé sur l'étude précédente, (2) à tester différentes méthodes de classification de ML afin d'identifier la plus performante, (3) à évaluer l'intérêt d'un lissage des comportements prédits avec un algorithme basé sur un HMM et (4) à évaluer les modèles inclus dans le cadre méthodologique avec des techniques permettant de les valider à l'échelle de la période d'observation.

4. Démarche

Une vue d'ensemble sur la démarche est proposée en Figure 15. L'ensemble des données accéléromètres et sur le comportement (cf. chapitre 2) a été utilisé pour répondre à ce problème d'optimisation. Les données accéléromètres des 86 vaches laitières couplées à plus de 57 heures d'observation ainsi été mobilisées de manière à disposer d'un jeu de données suffisamment représentatif de la variabilité intra et inter-individuelle.

Chapitre 4

Dans un souci d'optimisation des performances, plusieurs configurations de traitement du signal ont d'abord été testées, conformément aux recommandations proposées dans l'étude précédente. Quatre algorithmes de ML ont ensuite été mis en œuvre pour prédire les six principaux comportements des vaches laitières au pâturage, à savoir l'ingestion, la rumination en position couchée et en position debout, le repos en position couchée et en position debout, et la marche. Des classifieurs et des méthodes ensemblistes ont été testés, à savoir :

- L'algorithme de Support Vector Machine (SVM) (Annexe VII)
- L'algorithme de forêt aléatoire (RF) (Annexe VIII)
- L'algorithme AdaBoost (ADA) (Annexe IX)
- L'algorithme d'eXtreme Gradient Boosting (XGB) (Annexe X)

Le jeu de données complet a été séparé en jeu de données d'entraînement et de validation (ratio 2/3 ; 1/3) en faisant en sorte que les fenêtres de signal correspondant à une même séquence continue d'observation (15 minutes ; cf. chapitre 2) soient retrouvées exclusivement dans l'un ou l'autre des jeux de données. Une grille de valeurs pour les différents paramètres propres à chaque algorithme a été générée afin d'entraîner plusieurs modèles. Le modèle ajusté pour chacun des algorithmes testés a été obtenu au moyen d'une procédure de cross-validation réalisée sur le jeu de données d'entraînement. Le jeu de données de test a ensuite été utilisé pour la prédiction des comportements par chacun des modèles ajustés. Les comportements prédits ont finalement été lissés *via* l'algorithme de Viterbi basé sur un HMM. Le principe de cet algorithme est décrit en Annexe XI. Des métriques de performance (pourcentage de bon classement, Kappa, sensibilité et spécificité) ont été calculées sur la base des matrices de confusion obtenues avant et après lissage pour chacun des modèles ajustés de manière (1) à identifier l'algorithme de ML ayant conduit aux meilleures performances et (2) à évaluer l'intérêt d'un lissage *post* prédiction, notamment pour l'amélioration de la prédiction des postures des animaux.

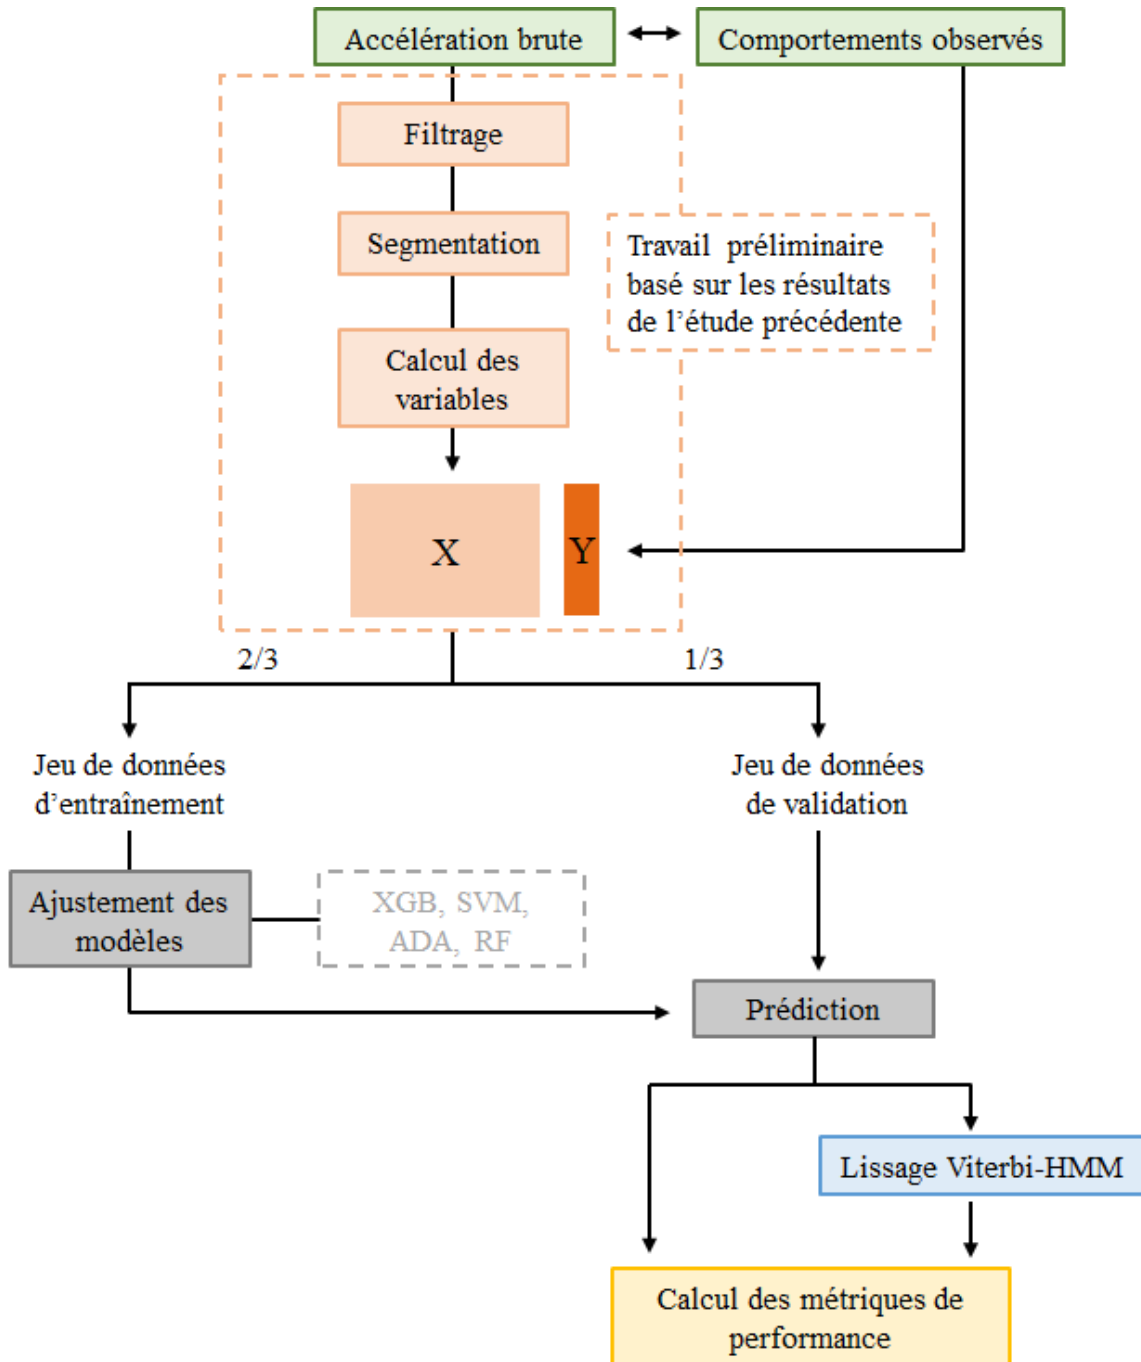


Figure 15. Vue d'ensemble sur la stratégie établie pour identifier la combinaison la plus adaptée pour prédire les comportements des vaches laitières au pâturage à partir de données accéléromètres.

5. Résultats

Les meilleurs résultats ont été obtenus avec XGB suivi du lissage par Viterbi, aboutissant à un pourcentage de fenêtres bien classées de 98 % et à un Kappa de Cohen de 0.96 sur le jeu de données test. Tous les comportements affichent une sensibilité supérieure à 84 %, à l'exception du comportement de repos en position debout pour lequel la sensibilité est de 78 %. La spécificité est supérieure à 99 % pour tous les comportements. Ces performances sont supérieures à celles obtenues dans les études similaires (Martiskainen *et al.*, 2009 ; Decandia *et al.*, 2018 ; Benaissa *et al.*, 2018). Le lissage par l'algorithme de Viterbi a surtout permis d'améliorer la sensibilité (+ 4 %) du comportement de repos en position debout. La validité des algorithmes évaluée à l'échelle de l'individu mérite néanmoins d'être améliorée. A ce propos, l'intégration de capteurs supplémentaires (magnétomètre, gyromètre) dans le même boîtier mériterait d'être considérée pour améliorer les performances du cadre méthodologique développé.

MESSAGE A RETENIR

D'excellentes performances de prédiction peuvent être obtenues pour l'ensemble des comportements principaux des vaches laitières au pâturage via un modèle d'eXtreme Gradient Boosting suivi d'un lissage par l'algorithme de Viterbi avec un accéléromètre fixé au collier. Les modèles proposés dans le cadre méthodologique ont été validés à l'échelle de la période d'observation mais la validation à l'échelle de l'individu mérite néanmoins d'être améliorée pour envisager les applications souhaitées.

6. Valorisation

Ce travail a donné lieu à un article accepté dans le journal *Computers and Electronics in Agriculture*.


Riaboff, L., Poggi, S., Madouasse, A., Couvreur, S., Aubin, S., Bédère, N., Goumand, E., Chauvin, A., Plantier, G., 2020. Development of a methodological framework for a robust prediction of the main behaviours of dairy cows using a combination of machine learning algorithms on accelerometer data. *Comput. Electron. Agric.* 169, 105179. <https://doi.org/10.1016/j.compag.2019.105179>

Références

- Arcidiacono, C., Porto, S.M.C., Mancino, M., Cascone, G., 2017. Development of a threshold-based classifier for real-time recognition of cow feeding and standing behavioural activities from accelerometer data. *Comput. Electron. Agric.* 134, 124–134. <https://doi.org/10.1016/j.compag.2017.01.021>
- Ayumi, V., 2016. Pose-based human action recognition with Extreme Gradient Boosting, in: 2016 IEEE Student Conference on Research and Development (SCORED). Presented at the 2016 IEEE Student Conference on Research and Development (SCORED), IEEE, Kuala Lumpur, pp. 1–5. <https://doi.org/10.1109/SCORED.2016.7810099>
- Babajide Mustapha, I., Saeed, F., 2016. Bioactive Molecule Prediction Using Extreme Gradient Boosting. *Molecules* 21, 983. <https://doi.org/10.3390/molecules21080983>
- Benaissa, S., Tuytens, F.A.M., Plets, D., Cattrysse, H., Martens, L., Vandaele, L., Joseph, W., Sonck, B., 2018. Classification of ingestive-related cow behaviours using RumiWatch halter and neck-mounted accelerometers. *Appl. Anim. Behav. Sci.* <https://doi.org/10.1016/j.applanim.2018.12.003>
- Dutta, R., Smith, D., Rawnsley, R., Bishop-Hurley, G., Hills, J., Timms, G., Henry, D., 2015. Dynamic cattle behavioural classification using supervised ensemble classifiers. *Comput. Electron. Agric.* 18–28. <http://dx.doi.org/10.1016/j.compag.2014.12.002>
- Hamäläinen, W., Järvinen, M., Martiskainen, P., Mononen, J., 2011. Jerk-based feature extraction for robust activity recognition from acceleration data, in: Intelligent Systems Design and Applications (ISDA), 2011 11th International Conference On. IEEE, pp. 831–836.
- Lush, L., Wilson, R.P., Holton, M.D., Hopkins, P., Marsden, K.A., Chadwick, D.R., King, A.J., 2018. Classification of sheep urination events using accelerometers to aid improved measurements of livestock contributions to nitrous oxide emissions. *Comput. Electron. Agric.* 150, 170–177. <https://doi.org/10.1016/j.compag.2018.04.018>
- Martiskainen, P., Järvinen, M., Skön, J.P., Tiirikainen, J., Kolehmainen, M., Mononen, J., 2009. Cow behaviour pattern recognition using a three-dimensional accelerometer and support vector machines. *Appl. Anim. Behav. Sci.* 119, 32–38.
- Moreau, M., Siebert, S., Buerkert, A., Schlecht, E., 2009. Use of a tri-axial accelerometer for automated recording and classification of goats' grazing behaviour. *Appl. Anim. Behav. Sci.* 119, 158–170. <https://doi.org/10.1016/j.applanim.2009.04.008>
- Rahman, A., Smith, D.V., Little, B., Ingham, A.B., Greenwood, P.L., Bishop-Hurley, G.J., 2018. Cattle behaviour classification from collar, halter, and ear tag sensors. *Inf. Process. Agric.* 5, 124–133. <https://doi.org/10.1016/j.inpa.2017.10.001>
- Rushen, J., Chapinal, N., de Passillé, A., 2012. Automated monitoring of behavioural-based animal welfare indicators. *Anim. Welf.* 21, 339–350. <https://doi.org/10.7120/09627286.21.3.339>
- Shi, H., Wang, H., Huang, Y., Zhao, L., Qin, C., Liu, C., 2019. A hierarchical method based on weighted extreme gradient boosting in ECG heartbeat classification. *Comput. Methods Programs Biomed.* 171, 1–10. <https://doi.org/10.1016/j.cmpb.2019.02.005>
- Smith, D., Rahman, A., Bishop-Hurley, G.J., Hills, J., Shahriar, S., Henry, D., Rawnsley, R., 2016. Behavior classification of cows fitted with motion collars: Decomposing multi-class classification into a set of binary problems. *Comput. Electron. Agric.* 131, 40–50. <https://doi.org/10.1016/j.compag.2016.10.006>
- Vázquez Diosdado, J.A., Barker, Z.E., Hodges, H.R., Amory, J.R., Croft, D.P., Bell, N.J., Codling, E.A., 2015. Classification of behaviour in housed dairy cows using an accelerometer-based activity monitoring system. *Anim. Biotelemetry* 3. <https://doi.org/10.1186/s40317-015-0045-8>

Chapitre 4

Yang, J., 2009. Toward physical activity diary: motion recognition using simple acceleration features with mobile phones, in: Proceedings of the 1st International Workshop on Interactive Multimedia for Consumer Electronics. ACM, pp. 1–10.



Development of a methodological framework for a robust prediction of the main behaviours of dairy cows using a combination of machine learning algorithms on accelerometer data

L. Riaboff^{a,d,*}, S. Poggi^b, A. Madouasse^e, S. Couvreur^c, S. Aubin^a, N. Bédère^{c,f}, E. Goumand^d, A. Chauvin^e, G. Plantier^a

^a ESEOTech – LAUM, 49000 Angers, France

^b INRAE, Agrocampus Ouest, Université de Rennes, IGEPP, F-35650 Le Rheu, France

^c URSE, Ecole Supérieure d'Agricultures, Univ. Bretagne Loire, 49000 ANGERS, France

^d Terrena Innovation, 44150 Ancenis, France

^e BIOEPAR, INRAE, Oniris, 44307 Nantes, France

^f INRAE, AGROCAMPUS OUEST, PEGASE, F-35590 Saint-Gilles, France

1. Introduction

Monitoring livestock behaviours is a useful way to detect breeding events such as oestrus (Kamphuis et al., 2012) and health events such as lameness (Chapinal et al., 2009). In pasture-based systems, monitoring the behaviour of grazing ruminants is also important to optimise animal intake and performance (Carvalho, 2013). However, these observations are time consuming, labour-intensive (Penning, 1983) and sometimes access to the animal is not easy, like in mountain environment (Schlecht et al., 2009). For these reasons, applications that involve sensors to automatically monitor the behaviour of livestock have grown rapidly over the last years (Rushen et al., 2012). Among available technologies, promising results have been obtained with accelerometers, already widely used for human activity recognition (Mathie et al., 2004). Accelerometers have been effective in discriminating behaviours of ruminants like grazing, ruminating or lying (Benaissa et al., 2018; Dutta et al., 2015; Robert et al., 2009), depending on where the sensor is attached to the animal. Accelerometers have also been used to predict specific events such as oestrus (Shahriar et al., 2016) or urination (Lush et al., 2018) of livestock for instance.

For their effective application in farming, sensors should provide information about a wide range of behaviours (Rutten et al., 2013). Animal's posture like standing or lying, and feeding behaviours like grazing or ruminating, are both crucial to detect health events and assist in pasture management. For example, Yunta et al. (2012) showed that lying bout durations are longer for moderately lame cows. Norrington et al. (2014) highlighted that lameness is associated with changes in feeding behaviour, thereby justifying that both posture and feeding behaviour should be taken into account to detect lameness. Concerning

pasture management, most of the studies focused on grazing, ruminating, resting and active behaviours (Andriamandroso, 2017; Giovanetti et al., 2017; Gonzalez et al., 2015), as these are the main behaviours affecting livestock performance. Collecting lying and standing time and identifying the main areas where animals carried out these behaviours is also a relevant information for pasture management and welfare monitoring (Martiskainen et al., 2009; Riaboff et al., 2018). In the latter studies, a satisfactory discrimination of two or three behaviours was obtained (Benaissa et al., 2018; Giovanetti et al., 2017) but the performance dramatically decreased when posture and feeding behaviours were investigated (Alvarenga et al., 2016; Martiskainen et al., 2009). Thus, the limited set of discriminated behaviours is currently a significant barrier to the practical use of sensors in farming (Dutta et al., 2015).

Behaviour prediction generally consists of the three-following steps (i) signal processing, (ii) feature extraction, and (iii) supervised learning for classification. Few studies have considered step (i) to improve the prediction although its importance has been demonstrated in human activity recognition (Bersch et al., 2014). Most authors have focused on step (ii) in selecting the best set of features (Smith et al., 2016). Concerning step (iii), different classification algorithms have already been compared to identify the most suitable classifier (Smith et al., 2016; Vázquez Diosdado et al., 2015). Regarding step (iii), Machine Learning methods have been widely considered, including Support Vector Machine (SVM) (Martiskainen et al., 2009) and Random Forest (RF) (Lush et al., 2018) but less complex methods have sometimes been applied, such as Discriminant Analysis (Barwick et al., 2018) or Decision Tree (Robert et al., 2009). Stochastic models such as Hidden Markov Models (HMM) have sometimes been used to incorporate

* Corresponding author at: ESEOTech – LAUM, 49000 Angers, France.

E-mail addresses: lucile.riaboff@eseo.fr (L. Riaboff), sylvain.poggi@inra.fr (S. Poggi), aurelien.madouasse@oniris-nantes.fr (A. Madouasse), s.couvreur@groupe-esa.com (S. Couvreur), sebastien.aubin@eseo.fr (S. Aubin), Nicolas.Bedere@inra.fr (N. Bédère), Etienn.Goumand@idele.fr (E. Goumand), alain.chauvin@oniris-nantes.fr (A. Chauvin), guy.plantier@eseo.fr (G. Plantier).

<https://doi.org/10.1016/j.compag.2019.105179>

Received 21 October 2019; Received in revised form 20 December 2019; Accepted 24 December 2019

0168-1699/ © 2019 Published by Elsevier B.V.

temporal information within the behaviour sequences but it seems less effective than common supervised algorithm (Vázquez Diosdado et al., 2015). Yang (2009) proposed a strategy which consists in first predicting human activities with a decision tree and then smoothing the outputs with an HMM-based Viterbi algorithm. As this 2 steps strategy allowed improving the accuracy of the prediction of human behaviour, it should be interesting to evaluate it for the prediction of livestock behaviour. Finally, regardless of the prediction methods used, the predictions obtained with the model are evaluated usually using independent windows of behaviours (Robert et al., 2009).

In this study, our aim was to develop a methodological framework for predicting 6 behaviours expressed by dairy cows at pasture and relevant for on-farm applications, using a three-dimensional accelerometer fixed on a neck-collar. The 6 behaviours of interest were grazing, walking, ruminating while standing, ruminating while lying, resting while standing and resting while lying. Our approach combined a raw signal pre-processing step investigated in a previous study (Riaboff et al., 2019) and the identification of the best machine learning algorithm among 4 under consideration (Random Forest (RF), Support Vector Machine (SVM), Adaboost (ADA) and eXtreme Gradient Boosting (XGB)). A temporal smoothing with an HMM-based Viterbi algorithm was finally applied to reassess the predictions of the behaviours obtained with the Machine Learning algorithms based on the temporal structure within the sequence of behaviours.

2. Material and methods

An overview of the applied methodological framework is provided in Fig. 1. Each step is detailed in the following sections.

2.1. Data collection

Data collection was carried out on four commercial dairy farms with 55–71 Holstein cows, located in the region Pays-de-la-Loire (France), during the summer of 2017, and the spring and summer of 2018. On each farm, cows that were equipped with a collar were selected based on stage of lactation (days in milk) and number of calvings (parity), as these factors are known to affect the time spent in different behaviours. Therefore, we selected cows between 60 and 300 days in milk, and representative of the herd in terms of parity. A total of 86 cows were equipped with a sensor through the study. Further details on farms and animals are presented in Table 1.

An RF-Track datalogger (RF-Track, Rennes, France) with a LSM9DS1 three-axis accelerometer (STMicroelectronics, Geneva, Switzerland) ± 2 g was used. Data were collected at 59.5 Hz. The accelerometer was powered with two 3.7 V lithium batteries (2.6 Ah). Data were stored on a SD card and downloaded after the experiment. The dataloggers were $98.2 \times 51.60 \times 36.0$ mm in size and weighed 250 g. The three-axis accelerometer was fixed on a collar and positioned on the right side of the neck as recommended by Smith et al. (2016). Collars were tightly adjusted and a 500 g counterweight was added to prevent them from turning around (Fig. 2) (Robert et al., 2009). The x-axis detected the up-down direction, the y-axis detected the backward-forward direction and the z-axis detected the left-right direction.

Each selected cow was equipped with the collar during one day of grazing on the first and second farm, 2, 4 or 6 days of grazing on the third farm depending on the cow, and 3 days of grazing on the last farm. Two trained observers recorded behaviours of the cows at pasture at each observation session. While one observer tracked one cow during 15 min, the other observer focused on another cow. All the cows equipped in the 4 farms were observed at least once by each of the two observers. Therefore, we collected a minimum of 30 min of observation per cow. A total of 57 h 21 min and 57 s of observation were performed. The main behaviours recorded are “grazing”, “walking”, “ruminating – lying”, “ruminating – standing”, “resting – lying” and “resting –

standing”. The behaviours “grooming”, “urinating”, “interaction with other cows”, “running”, “raising”, “lying down” and “grazing while lying” were also observed. As they were each poorly represented, they were combined as “Other”. The behaviours are defined in the ethogram detailed in Table 2. It should be noted that the concordance between the two observers was checked (percentage of agreement > 80%) to ensure that observations could be considered independent of the observer in the rest of the study.

The duration of observation and the number of cows for each behaviour are reported in Table 3.

2.2. Raw accelerometer signal processing

The pre-processing step aimed providing suitable datasets for the subsequent application of the classification algorithms. The pre-processing step was performed in Matlab R2018a. The total duration of observations led to 229 continuous signal sequences of 15-minutes. Due to a malfunction of 4 of the 30 sensors available, we collected only 199 continuous sequences. We first combined the 199 continuous sequences of raw accelerometer signal (thereafter referred to as **observation sequences**) with the corresponding field observations. It should be noted that the accelerometer signal and observations were time synchronized to ensure that direct observations were associated to the correct sequences of accelerometer signal.

These 199 observation sequences were then split into segments (time-window) of the same duration (size of the time-window). When more than one behaviour was associated to a time-window, this time-window was removed from its sequence. In this way, the features extracted from the signal windows were representative of each behaviour specifically, which is the most suitable to train the models. Consequently, the 199 initial continuous sequences of observation were split into shorter continuous sequences. Furthermore, time-windows associated to the “Other” class were discarded from the dataset. Indeed, it combined several behaviours so it is not possible to extract representative features for this class in a supervised classification context. Therefore, we focused on the 6 main behaviours. As signal segmentation may drastically alter the results of the prediction (Bersch et al., 2014; Robert et al., 2009; Smith et al., 2016) several configurations identified as affecting the quality of the prediction in a previous study (Riaboff et al., 2019) were evaluated. In particular, window sizes of 5 s and 10 s were evaluated as they are commonly used in similar studies (Robert et al., 2009), while 50% and 90% overlap were compared as recommended by Bersch et al. (2014). This resulted in testing four different pre-processing configurations. The best results were obtained with the configuration (10 s; 90%), in accordance with Riaboff et al. (2019). The number of observation sequences and time-windows obtained for the configuration (10 s; 90%) for every behaviour are presented in the Table 4. The study was carried out thereafter with this configuration exclusively.

A set of features was then extracted from each 10 s-window, both in the time and frequency domains. Features were computed from the raw signal () of X-axis (a_x), Y-axis (a_y) and Z-axis (a_z). The signal magnitude axis (a_{mag}), considered as orientation independent (Fida et al., 2015) was also computed (Appendix A). Each axis (a_x , a_y , a_z , a_{mag}) was high-pass filtered to get the dynamic component of the acceleration due to the body of the cow and noted $a_{dynamic_axis}$. A 6-th-order high-pass digital Butterworth filter with a cutoff frequency of 0.3 Hz (Smith et al., 2016) was applied to each axis of the raw data. The Overall Body Dynamic Acceleration (OBDA) and the Vector of the Dynamic Body Acceleration (VeDBA) were computed from the dynamic component. Each axis (a_x , a_y , a_z , a_{mag}) was also low-pass filtered to get the static component of the acceleration due to the gravity and noted a_{static_axis} . The pitch and roll angle were calculated on a_{static} . The sixty-seven calculated features are listed in Table 5. The formulas used to compute each feature are provided in the Appendix A.

It should be mentioned that the features perfectly correlated were

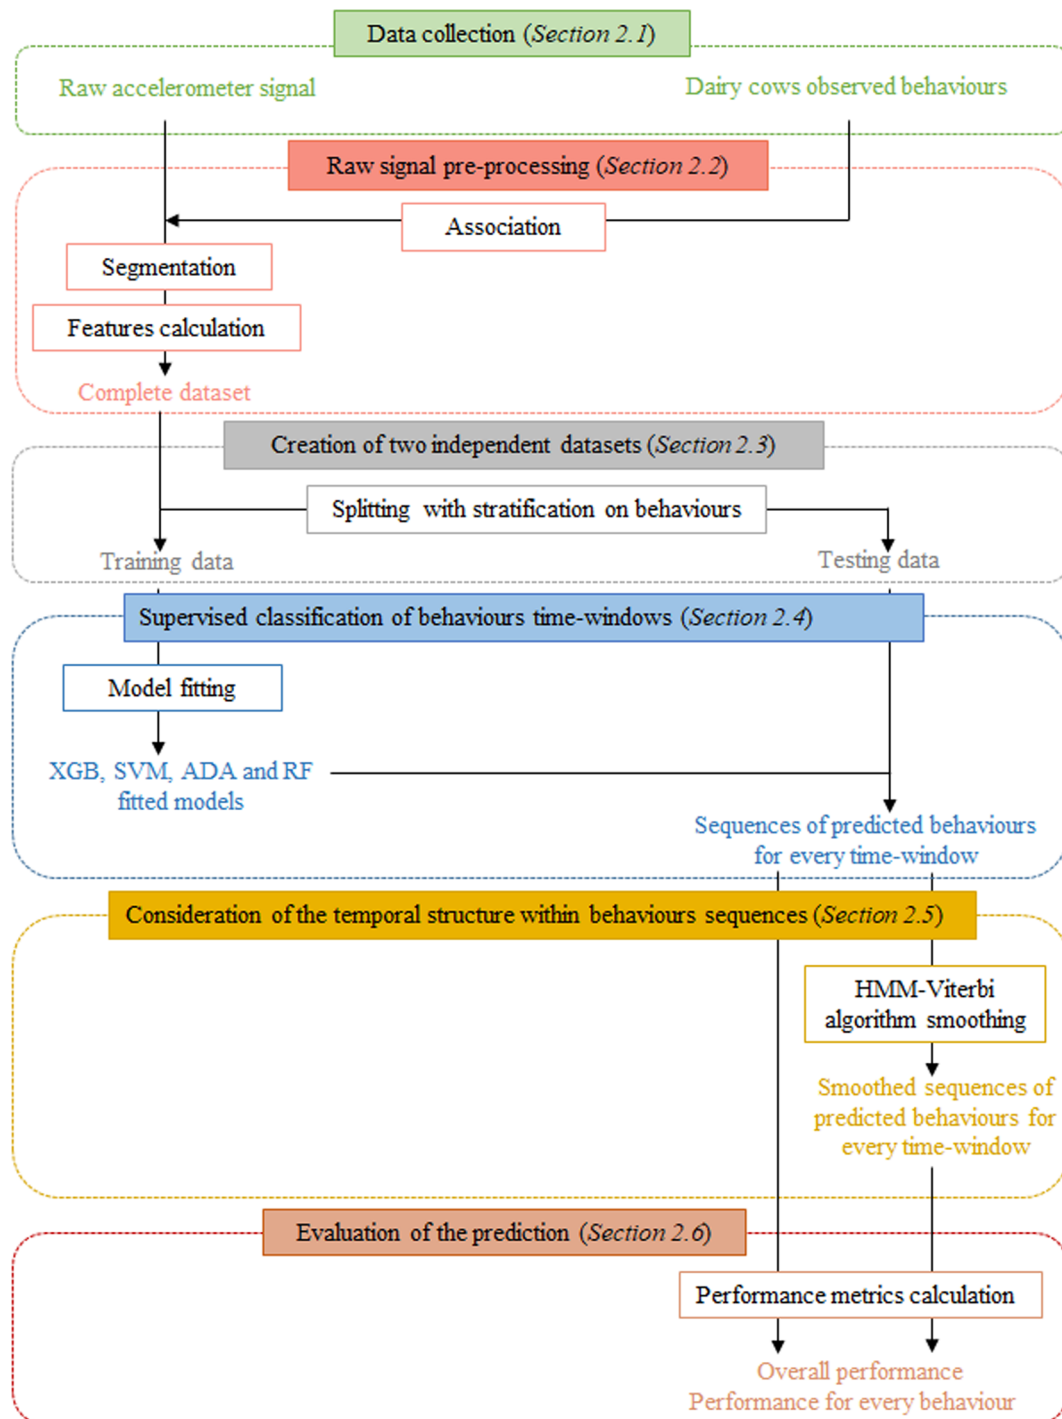


Fig. 1. Overview of the methodological framework used to predict the 6 main dairy cow behaviours at grazing.

excluded. Thus, the RMS on a_x , the mean and median on a_y , the mean on a_z , the RMS on a_{mag} , the pitch and VeDBA were not considered in the rest of the study. The features were finally normalized according to the equation presented in the Appendix A. Therefore, the complete dataset consisted of 61 features associated to each 10 s-window.

2.3. Creation of two independent datasets

As we are in a supervised classification context, the complete dataset was split into two independent datasets. Two-thirds of the 1794 observation sequences (Table 4) were randomly chosen to train the models and the remaining observation sequences were used to evaluate

them. Random sampling of observations was stratified by behaviour in order to make sure that each behaviour was equally frequent in both the training and testing datasets. Therefore, the training dataset was composed of the 10 s-windows belonging to the selected two-thirds observation sequences. The testing dataset was composed of the remaining 10 s-windows.

2.4. Supervised classification of behaviour time-windows

The aim of this step was to classify the 10 s-windows from each observation sequence optimally. For this purpose, four supervised Machine Learning algorithms were investigated. Details about the

Table 1
Farms and dairy cows under study.

Farm	GAEC Beiloin	GAEC Perrière	GAEC Haute-Roue	GAEC Harmonie
Location	Lion d'Angers, France (N 47°37'43", O 0°42'42")	Le Cellier, France (N 47°19'13", O 1°20'43")	La Pommeraye, France (N 47°21'21", O 0°51'33")	La Rouxière, France (N 47°26'37", O 1°03'59")
Period of experiment	July 2017	April 2018	May 2018	July 2018
Number of cows equipped/Herd size	10/71	12/55	40/70	24/61
Paddocks areas	0.3 ha	1.2 ha	From 0.6 to 2 ha	0.3 ha
Pasture access	Day and night	6 h a day	Day and night	6 h a day
Average grass height* (beginning of the observation)	12 cm	12 cm	15 cm	6 cm
Grasslands	Temporary grassland: mixture of <i>Lolium perenne</i> L. and <i>Trifolium repens</i> L.	Temporary grassland: mixture of <i>Lolium perenne</i> L. and <i>Trifolium repens</i> L.	Temporary grassland: mixture of <i>Lolium perenne</i> L., <i>Trifolium repens</i> L. and <i>Bromus hordeaceus</i> Permanent grassland: mainly containing <i>Lolium perenne</i> L., <i>Trifolium repens</i> L., <i>Dactylis glomerata</i> and <i>Holcus lanatus</i>	Temporary grassland: mixture of <i>Lolium perenne</i> L. and <i>Trifolium repens</i> L.
Supplement	Maize silage (10 kg/day), concentrate (2 kg/day) and hay (5 kg/day) after each milking	Maize silage (10 kg/day), concentrate (2 kg/day) and hay (5 kg/day) after each milking	Alfalfa hay (5 kg/day) once a day, a ration of Triticale – Peas – Field Beans (1.83 kg/day) after each AMS frequestration	Maize silage (10 kg/day), concentrate (2 kg/day) and hay (5 kg/day) after each milking
Milk yield (kg/cow/year)	10,000	9000	9000	8000

* Grass height measurements were carried out with the GrassHopper® plate meter (McSweeney et al., 2015) in the pastures before the beginning of the experiment.



Fig. 2. RF-Track 3D accelerometer and GPS sensor fixed on the collar on the cow. The three coordinate axes of the accelerometer sensor are displayed.

considered algorithms and the methodology used to fit the models and predict behaviours are provided in the following sections.

2.4.1. Description of the considered Machine Learning algorithms

- Extreme Boosting Algorithm (XGB)

XGB is an ensemble classifier derived from the gradient boosting decision tree (Friedman, 2001). XGB combines weak base classifiers into a strong classifier. At each iteration of the training process, the residual of a base classifier is used in the next classifier for optimizing the objective function. In addition, XGB introduces a regularization term to control the complexity of the model and thus prevents overfitting (Shi et al., 2019). Hyperparameters to tune are listed below:

- *nrounds*: number of boosting iterations.
- *max_depth*: maximum depth of a tree. High values will tend to complicate the model with likely overfitting.
- *eta*: controls the learning rate. After each boosting step, it scales the contribution of each tree by a factor range between 0 and 1. In this manner, it prevents overfitting by making the boosting process more conservative.
- *gamma*: minimum loss reduction required to make a further partition on a leaf node of the tree. The smaller, the less conservative the algorithm will be.
- *colsample_bytree*: subsample ratio of columns when constructing each tree.
- *min_child_weight*: minimum sum of instance weight needed in a child. As long as the tree partition step results in leaf nodes with the sum of instance weight above *min_child_weight*, the building process continues. The larger, the more conservative the algorithm will be.
- *subsample*: subsample ratio of the training instances. For instance, a subsample value of 0.5 means that XGB would randomly sample half of the training data prior to growing trees. Subsampling will occur once in every boosting iteration.

The XGB algorithm was applied using the R package xgboost (Chen et al., 2018) in R 3.6.1 software (R Core Team, 2019).

- Support Vector Machine (SVM)

SVM is a supervised binary classification method (Burges, 1998). The basic idea of the multi-class SVM problem is to construct *k* classifiers, one for each class. The *k*th classifier constructs an optimal hyperplane between class *n* and the *k* – 1 other classes. To construct the optimal separating hyperplane, a kernel function is used to transform the input data into a high-dimensional space. Hyperparameters to tune are:

Table 2
Definition of the different behaviours under study.

Behaviour	Classification description
Grazing	Biting or browsing taking frequent bites, without raising the head
Walking	Movement from one location to another without lowering the head at ground level
Ruminating – Lying	Lying with regurgitating rumen bolus before it is chewing and then re-swallowing
Ruminating – Standing	Standing with regurgitating rumen bolus before it is chewing and then re-swallowing
Resting – Lying	Lying without rumination
Resting – Standing	Standing without movement or rumination
Other	All remaining behaviours

Table 3
Duration of observation and number of cows for each behaviour.

Behaviour	Duration (HH:MM:SS)	Number of cows
Grazing	27:38:57	62
Walking	01:10:19	60
Ruminating – Lying	08:05:26	44
Ruminating – Standing	03:34:27	35
Resting – Lying	08:00:00	57
Resting – Standing	03:40:10	66
Other	05:12:38	79
Total	57:21:57	86

Table 4
Number of sequences including each behaviour and number of time-windows associated with every behaviour for the selected configuration (10 s; 90%).

	Number of sequences including the behaviour	Number of windows associated with the behaviour
Grazing	814	63,136
Walking	110	2155
Ruminating – Lying	504	18,203
Ruminating – Standing	200	7024
Resting – Lying	94	20,084
Resting – Standing	131	7222
Total	1794	117,824

Table 5
Abbreviation for each of the calculated features and list of the associated publications.

Abbreviation	Full name	References
\bar{A}	Average	Barwick et al. (2018) and Smith et al. (2016)
σ^2	Variance	Figo et al. (2010)
σ	Standard deviation	Bersch et al. (2014) and Smith et al. (2016)
<i>Min</i>	Minimum	Barwick et al. (2018) and Figo et al. (2010)
<i>Max</i>	Maximum	Barwick et al. (2018) and Figo et al. (2010)
<i>Range</i>	Range	Figo et al. (2010)
Q_2	Median	Fida et al. (2015)
Q_1	First quartile	Figo et al. (2010)
Q_3	Third quartile	Figo et al. (2010)
<i>IQ</i>	Interquartile range	Figo et al. (2010)
<i>RMS</i>	Root Mean Square X-axis	Bersch et al. (2014)
<i>SMA</i>	Signal Magnitude Area	Barwick et al. (2018)
<i>AI</i>	Average Intensity	Barwick et al. (2018)
<i>MV</i>	Movement Variation	Barwick et al. (2018) and Lush et al. (2018)
β_1	Skewness	Dutta et al. (2015) and Martiskainen et al. (2009)
β_2	Kurtosis	Dutta et al. (2015) and Martiskainen et al. (2009)
<i>Max_corr_{xy}</i>	The maximum of the correlation	Figo et al. (2010)
H_s	Spectral entropy	Zaccarelli et al. (2013)
<i>OBDA₁</i>	Overall Body Dynamic Acceleration	Benaissa et al. (2018)
<i>OBDA₂</i>	Overall Body Dynamic Acceleration	Wilson et al. (2008)
<i>VeDBA</i>	Vector of the Dynamic Body Acceleration	Walker et al. (2015)
<i>pitch</i>	Pitch angle	Walker et al. (2015)
<i>roll</i>	Roll angle	Walker et al. (2015)

- C: cost of constraints violation. The larger, the smaller the margin of the hyperplane will be.
- *sigma*: inverse kernel width for the Radial Basis kernel function.

The SVM algorithm was applied using the R package kernlab (Karatzoglou et al., 2004) in R 3.6.1 software (R Core Team, 2019).

- Adaboost (ADA)

Adaboost is a boosting algorithm where the weak classifiers are decision trees with a single split. Adaboost works by affecting more weight on instances which are difficult to classify and less on those already correctly classified. In this way, boosting promotes new models capable of correctly classifying instances which were misclassified by earlier models. The impact of each model is weighted depending on its performance instead of offering the same weight to all models. Thus, the final model converges to a strong classifier (Subasi et al., 2018). Hyperparameters to tune are:

- *max_depth*: maximum depth of a tree. High values will tend to complicate the model with likely overfitting.
- *mfinal*: number of iterations for which boosting is run or the number of trees to use.

The Adaboost algorithm was applied using the R package adabag (Alfaro et al., 2013) in R 3.6.1 software (R Core Team, 2019).

- Random Forest (RF)

Random Forest is a bagging algorithm where many decision trees are randomly built. A subset of variables and samples are randomly chosen to build each decision tree. Each node of the decision trees aims at segmenting the subset of samples using the randomly selected variables. The target is to find the segmentation leading to the purest classification, *i.e.* leading to a maximum of instances of the same class in every node. For the classification tree, the Gini index is usually used to evaluate the decrease of impurity after each split. The final classification is carried out using every random decision trees (Breiman, 2001). Hyperparameters to tune are:

- *ntree*: number of iterations to carry out, *i.e.* number of decision trees to build.
- *mtry*: number of variables to choose at each iteration to build the decision tree.

The RandomForest algorithm was applied using the randomForest package (Liaw and Wiener, 2002) in R 3.6.1 software (R Core Team, 2019).

2.4.2. Models fitting and prediction of behaviour time-windows

The 4 Machine Learning models were fitted using the training data. For this purpose, several combinations of hyperparameters were tested from a generated grid of values specific to each algorithm (Section 2.4.1). For each combination of hyperparameters, the model was evaluated using a 10-fold cross validation procedure repeated three times. The accuracy and Cohen’s Kappa associated with the prediction

of each tested model were collected. This step was carried out with the R package caret (Kuhn et al., 2018) in R 3.6.1 (R Core Team, 2019). For each algorithm, the model leading to the best performance, called the fitted model, was applied to predict a behaviour in each 10 s-window using the testing data. At the end of this supervised classification step, the sequences of predicted behaviours for every 10 s-window were obtained for the 4 Machine Learning algorithms.

2.5. Consideration of the temporal structure within behaviours sequences

In order to account for the fact that the probability for a cow of expressing a specific behaviour at a given time depends on the behaviour she expressed just before, an HMM-based Viterbi algorithm using the behaviours predicted by the Machine Learning algorithms as input was used to predict its actual behaviours. The assumptions common to all HMMs are i) that the observations (behaviours predicted by the Machine Learning algorithms) are imperfect measures of a true state (actual behaviours) and that ii) the true states undergo Markovian transitions whereby the probability of being in a state at time t (within a given time window), only depends on the true state at time $t - 1$ (in the previous time window). Therefore, as proposed by Yang (2009), the goal of this smoothing step was to reassess the predictions of the behaviours obtained with the Machine Learning algorithms for each sequence of observation. The principle of the HMM-based Viterbi algorithm smoothing is illustrated in Fig. 3. All the matrices and vectors defining the HMM and mentioned in Fig. 3 are explained in the following sections.

The HMM-model noted Λ was used to estimate the unknown states of the process noted S , *i.e.* the behaviours actually carried out by the




Fig. 3. Principle of the smoothing with the HMM-based Viterbi algorithm.

Table 6
Hyperparameters of fitted models for every algorithm.

Algorithm	Parameters of fitted models
XGB	nrounds = 250 max_depth = 6 eta = 0.4 gamma = 0 colsample_bytree = 0.8 min_child_weight = 1 subsample = 0.75
SVM	C = 128 sigma = 0.05
ADA	max_depth = 29 mfinal = 150
RF	mtry = 15 ntrree = 2000

cows, knowing the measurable observations noted V , i.e. the behaviours predicted by the Machine Learning algorithms (Witten and Frank, 2011). The HMM Λ was also based on a transition matrix T providing the probability to move from a state, i.e., a behaviour, to another at the next time-window. The transition matrix was obtained empirically, based on the data collected experimentally. The HMM was also defined by its emission matrix E , representing the probability that each observation was generated by each state. The emission matrix corresponds to the confusion matrix resulting from the prediction of the model. Finally, initial probabilities of each state, noted π , were finally used to define the HMM. The vector of initial probabilities was computed with the experimental data. All the matrices and vector used to define the HMM Λ in this study are detailed in Appendix B. A more detailed definition of the HMM is provided in the Appendix C. The function “initHMM” of the R package HMM (Himmelmann, 2010) in R 3.6.1 software (R Core Team, 2019) was used to define HMM-models.

The Viterbi algorithm was finally applied to find the most probable hidden behaviour from the preceding behaviour, based on the HMM $\Lambda = (T, E, \pi)$. We refer the reader to Forney (1973) for a more detailed description of the Viterbi algorithm. The Viterbi algorithm was applied with the function “viterbi” of the R package HMM (Himmelmann, 2010).

2.6. Evaluation of the prediction

The prediction was evaluated before and after smoothing with the HMM-based Viterbi algorithm. The overall performance of the models was evaluated with the accuracy, corresponding to the percentage of well-classified instances. The Cohen’s Kappa (Cohen, 1960) was also used to assess performance. This metric provides the agreement between observation and prediction from a model. According to the criteria proposed by Cohen (1960), a Kappa higher than 0.81 was considered as an almost perfect agreement. The sensitivity and specificity of every behaviour were also calculated to evaluate the prediction of every behaviour. The sensitivity assessed the ability to return a positive outcome when the hypothesis is true. The specificity assessed the ability to return a negative outcome when the hypothesis is false. The equations for each parameter are provided in Appendix D. All the indicators were computed with the caret package (Kuhn et al., 2018) in R 3.6.1 (R Core Team, 2019).

3. Results

3.1. Results of model fitting

The fitted models obtained for each algorithm are presented in Table 6.

The accuracy and Cohen’s Kappa got for every fitted model are provided in Fig. 4.

Both accuracy and Cohen’s Kappa were higher than 0.99 for all the algorithms using a 10-fold cross validation with the training data. The best performance was obtained with the XGB algorithm followed by the RF algorithm (Fig. 4.).

3.2. Results of the models using independent observation sequences

3.2.1. Overall performance

The overall performance of every model before and after the HMM-based Viterbi smoothing are presented in Table 7. The confusion matrices obtained for every prediction before smoothing are shown in Appendix E and Appendix F, respectively.

The highest performance was obtained with XGB after smoothing (accuracy: 0.98; Cohen’s Kappa: 0.96) followed by RF (accuracy: 0.97; Cohen’s Kappa: 0.95). The lowest performance was obtained with the ADA algorithm before smoothing (accuracy: 0.95; Cohen’s Kappa: 0.91). It should be noted that the smoothing with the HMM-based Viterbi algorithm did not appear to improve the overall performance of the models.

3.2.2. Discrimination of every behaviour

The prediction with the fitted models of XGB, RF, SVM and ADA was also evaluated for every behaviour, before and after smoothing. The sensitivities and the specificities of the predictions for every behaviour for the four algorithms are detailed in Fig. 5.

The best prediction results were obtained with XGB for every behaviour, except for the behaviour “Resting – Standing” where the sensitivity was higher with SVM (XGB: 0.78 and SVM: 0.82). The lowest performance was obtained with ADA, except for the sensitivity of “Walking” (0.78) and the specificity of “Grazing” (0.99) where the performance was lower with SVM (0.70 and 0.99, respectively).

The best prediction was obtained for the behaviour “Grazing” (sensitivity: 1.00 ± 0.00 ; specificity: 0.99 ± 0.00). The behaviour “Ruminating – Lying” also reached a sensitivity and a specificity higher than 0.97 and 0.99 after the HMM-based Viterbi smoothing, respectively. Similarly, the sensitivity and the specificity of the behaviour “Ruminating – Standing” were higher than 0.92 and 0.99 after smoothing, respectively. However, the sensitivity of the behaviour “Resting – Standing” reached a maximum of 0.82 with XGB after smoothing. The models also failed in the prediction of the behaviour “Walking” with a sensitivity lower than 0.80, except for the algorithm XGB where a sensitivity of 0.84 was obtained after smoothing.

It should be noted that the HMM-based Viterbi smoothing improved substantially the sensitivity of the behaviour “Resting - Standing” ($+ 0.04 \pm 0.01$) for which performance with the Machine Learning algorithm were the lowest.

4. Discussion

4.1. Improved performance in behaviour prediction in comparison with similar studies

Within the methodological framework proposed in the present study, the best prediction of dairy cow behaviours was obtained by combining (i) a preliminary study to find the most appropriate pre-processing of the raw accelerometer signal (window size of 10 s; overlap of 90%), (ii) a classification-prediction of the behaviours with the XGB algorithm, and (iii) a smoothing of the predictions using the HMM-based Viterbi algorithm. In the test dataset, the observed behaviours were predicted with an accuracy of 0.98 and a Cohen’s Kappa of 0.96. The sensitivities and specificities were above 0.90 for all the behaviours, except for the behaviour “Resting–standing” behaviour (sensitivity: 0.82) and for the behaviour “Walking” (sensitivity: 0.84). Considering (1) the range of predicted behaviours, (2) the number of accelerometers fixed on the cows and (3) the method used to validate the models, these results appear better than those reported in the



Fig. 4. Results of model fitting for every algorithm.

Table 7
Prediction results (accuracy and Cohen's Kappa) before and after smoothing for every algorithm.

Algorithm	Accuracy		Cohen's Kappa	
	Before smoothing	After smoothing	Before smoothing	After smoothing
XGB	0.97	0.98	0.96	0.96
RF	0.97	0.97	0.95	0.95
SVM	0.96	0.97	0.94	0.95
ADA	0.95	0.95	0.91	0.92

literature.

4.1.1. Prediction with a large range of behaviours

A satisfactory prediction has already been obtained in similar studies when few behaviours were predicted. For instance, [Andriamandroso \(2017\)](#) have reached an accuracy of 0.92 to predict the 3 behaviours “Ruminating”, “Grazing” and “Other” behaviours. [Benaissa et al. \(2018\)](#) have also predicted the same 3 behaviours with an accuracy of 0.93 using SVM. However, it should be noted that the behaviour “Other” was predicted in these two studies, which is also challenging as this class combined several different behaviours. The 3 behaviours “Grazing”, “Ruminating” and “Resting” were also predicted

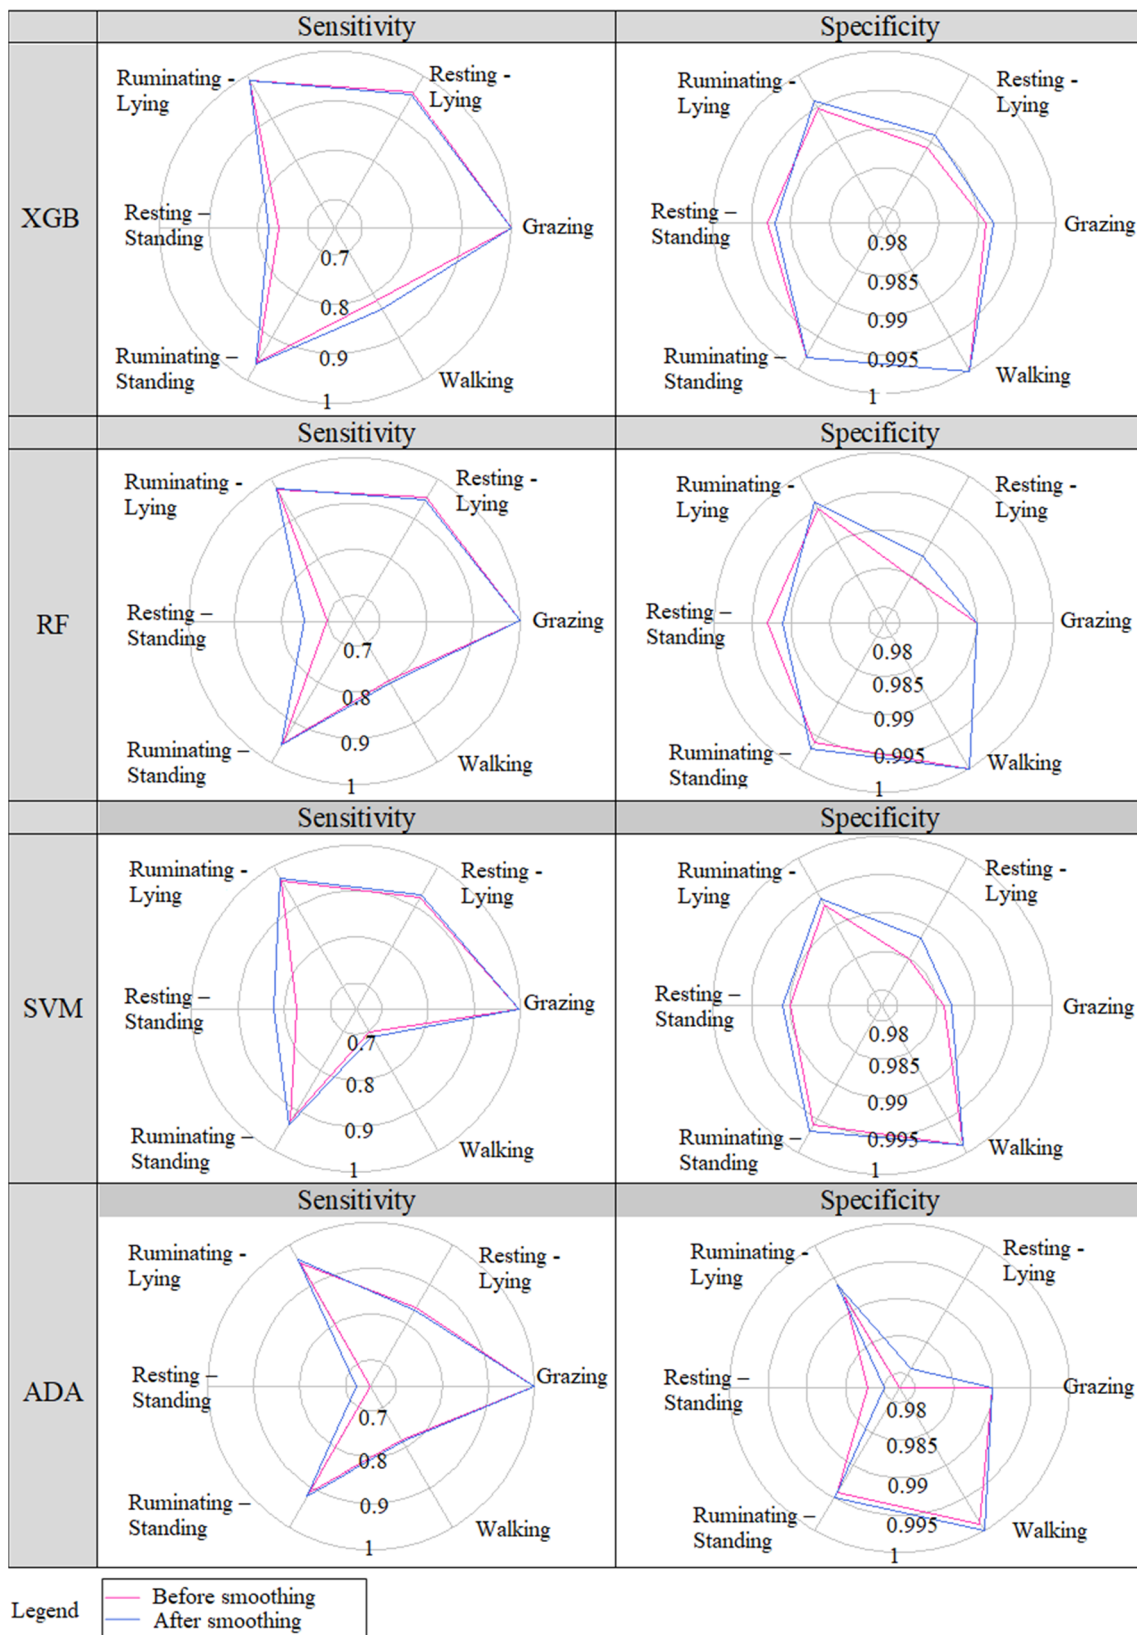


Fig. 5. Sensitivity and specificity of each behaviour for every algorithm, before and after smoothing with the HMM-based Viterbi algorithm.

with the satisfactory accuracy of 0.93 using a discriminant analysis (Giovannetti et al., 2017). However, in most studies, the performance drastically decreased when more behaviours were considered. For instance, Martiskainen et al. (2009) predicted 8 behaviours involving

feeding behaviours as well as posture of cows using SVM. Their indicator called precision reached a value of 0.78 and a Cohen's Kappa of 0.69. In the same way, Alvarenga et al. (2016) predicted the behaviours "Grazing", "Lying", "Running", "Standing" and "Walking" of sheep and

obtained an accuracy of 0.85 and a Cohen's Kappa of 0.79 using a window size of 5 s with a decision tree. Thus, our methodological framework seems to provide better performance than those obtained in similar studies in which both posture and feeding behaviours have been considered.

4.1.2. Prediction with a single sensor fixed on the neck

High performance has already been obtained when 2 sensors were fixed at 2 different positions on the animal. Indeed, the chosen behaviours are more or less well-predicted depending on the position of the sensor on the animal (Benaissa et al., 2017). For this reason, in order to predict both feeding behaviours and posture ("Lying", "Standing" and "Feeding") of cows, Benaissa et al. (2017) fixed an accelerometer on a neck-collar and another one on the leg to reach an accuracy of 0.98. However, fixing several sensors is tedious for both animals and handlers, as well as costly. As the procedure developed in this study aims to be used for practical implementations in farming, we chose to use a single sensor. It is indeed safer and more convenient for both farmers and animals than fixing several sensors at different places.

4.1.3. Reliable validation of the models

In many similar studies, each labelled window is affected either to the training dataset or to the testing dataset, independently of the sequence of observations to which the window belongs to (Lush et al., 2018; Martiskainen et al., 2009). Consequently, time-windows from the same cow at the same period of observation can be found in both training data and testing data. Due to the temporal structure of subsequent behaviours, the time-windows from the same sequence of observation are highly correlated. As explained by Rahman et al. (2018), the feature space distribution between the training data and the testing data is therefore very similar. The prediction is systematically better with this approach but this is not suitable to validate the algorithm. For instance, Lush et al. (2018) have predicted the behaviours "Foraging", "Walking", "Running", "Standing", "Lying" and "Urination event" in sheep with an accuracy of 0.96 and a Cohen's Kappa of 0.95 using Random Forest. However, 75% of the labelled windows were used to train the model and the remaining 25% were used to evaluate it, independently of the sequence of observation to which each window belongs. In our study, performance remained strong while windows from the same sequence of observation were either in the training data or in the testing data.

4.2. Methodology used to get a high performance

4.2.1. Field observation data

As noted by other authors (Rahman et al., 2018), the high between-cow variability in the recorded signal can decrease the performance of the prediction. For this reason, during data collection, particular attention was paid to cover as much variability as possible. Observations were carried out on 86 Holstein cows from 4 farms, of different parities and stages of lactation. The observations were also carried out in different paddocks (temporary *versus* permanent grasslands) and at different periods (summer of 2017 and spring and summer of 2018). In similar studies, the number of observed animals usually ranges between 5 and 40 animals from the same farm (Alvarenga et al., 2016; Lush et al., 2018). To the authors' knowledge, the dataset collected is larger and covers a wider range of conditions than those usually met in literature. As a consequence, the model was trained on a wider range of situations than what is usually found in the literature which could have decreased the performance of the prediction but which makes our conclusions more robust.

4.2.2. Appropriate pre-processing

The effect of the accelerometer signal pre-processing was widely approved in detection of human activities (Bersch et al., 2014). This aspect has received less attention in livestock monitoring behaviour,

except for the impact of the window size (Robert et al., 2009; Smith et al., 2016). In a preliminary study, we identified window size and the percentage of overlap between windows to be critical when pre-processing the data (Riaboff et al., 2019). In the present work, two different window sizes and two different percentages of overlap were evaluated. This allowed predicting the behaviours with a pre-processing configuration favourable to strong performance of prediction.

4.2.3. Comparison of Machine Learning algorithms including eXtreme Gradient boosting

High performance has already been obtained in similar studies with SVM (Smith et al., 2016) and RF (Lush et al., 2018). The Adaboost algorithm has only been tested by Dutta et al. (2015) for monitoring livestock behaviour, whereas its efficiency has already been approved in other prediction problems (Subasi et al., 2018). To the best of our knowledge, the XGB algorithm has never been applied to the prediction of livestock behaviour, despite its high performance in other areas (Shi et al., 2019). The best prediction was reached with XGB in this study. We therefore advise considering the XGB algorithm to predict livestock behaviours with accelerometer data.

4.2.4. Consideration of the temporal structure within the behaviour sequences

The Viterbi algorithm based on HMM uses the temporal structure within observation sequences to find the most probable sequence of behaviours, given a sequence of predicted behaviours obtained with the Machine Learning algorithm. This approach may be particularly relevant to predict behaviours for which there is *a priori* no relevant feature from accelerometer data to achieve the discrimination. For instance, this is the case for the behaviours standing and lying as both the level of activity and the head position are similar (Martiskainen et al., 2009).

Yang (2009) showed that the accuracy of the prediction of daily activities in humans using a decision tree increased by 0.06 after the Viterbi smoothing. Although the improvement was less substantial in our study, the sensitivity of the behaviour "Resting – Standing" for which the lowest performance was obtained with the Machine Learning algorithms was increased considerably (+ 0.04 ± 0.01).

4.3. Practical implications of the study

There is currently no reliable decision support tool to help pasture-based systems, neither for the pasture management, nor for the monitoring of animal health and welfare. The methodology developed in this study could be integrated in such a tool.

4.3.1. Pasture management support

In rotational grazing systems, a variation of 10% of milk yield can be explained by the fresh grass available to animals (Fulkerson et al., 2005). The allocation of fresh grass regulated by the rotation of the cows in the pastures is therefore critically important to keep high milk yield. Thus, a decision support tool indicating to farmers the appropriate time to allocate new fresh grass to the dairy cows would be relevant in pasture-based systems. Both changes in the lying behaviour (O'Driscoll et al., 2019) and feeding behaviour (Werner et al., 2019) are expected when the quantity and the quality of grass decline. In this respect, our methodology could be used to predict such behaviours. Other algorithms are also required to detect when there is not enough grass, based on the predicted behaviours. An automatic detection system to assist pasture management in rotational grazing systems could thus be developed, even if a work is still required on the technological aspects to make the system functional (battery life, computation time, automatic data transfer, etc.). In particular, a trade-off has to be found for the sampling rate in order to obtain both a satisfactory accuracy and a battery life compatible with the desired application (Benaissa et al., 2018).

4.3.2. Animal monitoring at pasture

- Detection of health events: the particular case of lameness detection

Some studies have shown that lameness is associated to changes to the behaviours of dairy cows (Chapinal et al., 2009), suggesting that behaviours could be used to detect lame cows (Barker et al., 2018). So far, the association between behaviour and lameness has been assessed considering either the lying behaviour (Yunta et al., 2012) or the feeding behaviour (Norrington et al., 2014). As mentioned by Willshire and Bell (2009), the combination of lying behaviour with feeding behaviour should help to improve both sensitivity and specificity of lameness detection, which are currently low (Rutten et al., 2013). Consequently, the methodological framework developed in our study may be relevant to the development of sensors predicting cow behaviour for the detection of lameness. Other algorithms are needed to detect lameness based on the predicted behaviours. Some technological aspects of the sensor should also be improved (battery life, automatic data transfer, computation time, etc.). This would alert automatically the farmer when a lame cow is detected to provide earlier treatments and mitigate the pain and costs associated with the disease (Willshire and Bell, 2009).

- Detection of a lack of comfort at pasture

Even if grazing is favourable to animal welfare (Burow et al., 2013), some stressful situations can also occur at pasture. For instance, Schütz et al. (2010) have shown that heat stress can occur when the temperature increases and there is no shadow in the paddock. In such situations, the distance of animals from the barn compromises the detection of the event by the farmer. As explained by Rushen et al. (2012), cow behaviour is a relevant indicator to assess welfare in farming but the biggest problem is the limited range of behaviours that have been measured automatically. In that regard, our methodological framework gives the opportunity to get information about the whole range of the main dairy cows' behaviours at pasture. An abnormal expression of one of the 6 considered behaviours could allow the detection of welfare issues in particular if the behaviours are combined with the position of the cows collected with a GPS sensor. As an example, Riaboff et al. (2018) identified a heat stress situation through an overexpression of the behaviour "Resting" close to the drinking trough. Thus, our methodology could be used as a basis for the development of algorithms for detecting stressful events, even if some improvements on the technological aspects of the sensor are still needed, as previously explained. Such a tool would be a way to monitor 4 out of the 5 fundamental freedoms (Farm Animal Welfare Committee (FAWC), 2011), namely "Do not suffer from hunger and thirst", "Do not suffer from discomfort", "Do not suffer from pain, injuries and illnesses" and "Do not be afraid or stressed".

4.4. Limitations of the studies and potential solutions

4.4.1. Overestimation of the model accuracy in an experimental context

- Validation of the models with the same cows

In this study, each algorithm was evaluated at the observation sequence level, as discussed in Section 4.1.3. Consequently, the signal windows from the same observation sequence were either in the training data or in the testing data. However, windows from the same cow can be found in both datasets as the cows were observed several times during the experiment. Considering the cow-level, *i.e.* with windows from the same cow either in the training data or in the testing data, is the most accurate way to assess the model performance. This approach is sometimes considered in similar studies (Rahman et al., 2018) and leads to moderate performance, with an accuracy usually below 0.90 when a single sensor has been used. This method led also to a decrease of performance in our study, with an accuracy of 0.85 and a

Cohen's Kappa of 0.76 using the XGB algorithm (*data not shown*). This decrease in performance is mainly due to the differences in the physical movement between dairy cows, leading to different motion patterns from a cow to another (Rahman et al., 2018). A way to improve the genericity of the algorithm may consist in considering a higher number of cows from various farms. Adding other sensors in the same electronic box fixed on the neck-collar could be also a way to better predict posture behaviours and then improve the genericity of the model.

- Removal of the remaining behaviours from the dataset

As explained in Section 2.1, behaviours other than the 6 under investigation, *i.e.* the "Other" class, were removed from the dataset. However, dairy cows can express these behaviours in real field situations. In these cases, the model will fail in the prediction because it has not been trained to predict these specific behaviours. Consequently, the prediction accuracy in real field situations will certainly be lower than in our development context. As the "Other" class is a combination of several behaviours, it is not possible to extract representative features for this class. Consequently, training a Machine Learning algorithm to predict the "Other" class does not seem appropriate. A solution would be to collect observations about each specific additional behaviour and then train the model to predict each event, as proposed by Lush et al. (2018) for the urination event.

- Using signal windows associated to a unique behaviour

As explained in Section 2.2, the signal sequences were split into 10 s-windows associated to a unique behaviour. These windows were then used to train the Machine Learning models. In a real field situation, dairy cows can express different behaviours within the same time window even if we chose a short window duration to prevent this issue. As the model has not been trained with heterogeneous time windows, the prediction may be wrong in such cases. This is another reason why the accuracy of the model might be reduced in real field situations. It would be interesting to train and test the models with heterogeneous windows in a second step to compare the accuracies, as proposed by Benaissa et al. (2018).

4.4.2. Confusion between the prediction of standing and lying

The lowest performance was obtained for the behaviour "Resting – Standing" (sensitivity: 0.82, specificity: 0.99 with XGB after smoothing) because of the confusion between the behaviour "Resting – Lying" (Appendix E). This confusion has already been mentioned in the literature when a single accelerometer is fixed on the animal neck (Benaissa et al., 2018; Martiskainen et al., 2009). As explained by Hamalainen et al. (2011), both the level of activity and the position of the head are similar between these two postures. Thus, it is difficult to find relevant features from accelerometer data alone to discriminate these two postures. Although this confusion was reduced with the Viterbi-based-HMM smoothing (Appendix F), the discrimination between these two postures remains an important challenge when using a single accelerometer on the neck. A solution might be to add other sensors in the same electronic box, like a magnetometer, a gyrometer or an altimeter. By merging data from different sensors, new relevant features could be found to discriminate lying and standing positions.

5. Conclusion

This study aimed to develop a methodological framework to predict feeding behaviour and posture of dairy cows at pasture from accelerometer data. For this purpose, a suitable pre-processing of the raw accelerometer signal was applied (10 s time-window, 90% overlap) and several methods of Machine Learning were compared (eXtreme Gradient Boosting, Random Forest, Support Vector Machine and Adaboost). The subsequent application of a Viterbi algorithm was used

to account for the temporal structure within behaviour sequences. The best prediction capacity was obtained using the XGB algorithm followed by the Viterbi smoothing, leading to an accuracy of 0.98 and a Cohen's Kappa of 0.96 on a test dataset. These prediction results were higher than those obtained in the similar studies. Our methodology therefore has great potential for the development of decision-support tools in grazing systems, both for assisting pasture management and for monitoring animal health and welfare.

The methodology led to an excellent accuracy of the prediction of the behaviours but some improvements are still needed. It is still difficult to discriminate the standing from the lying posture of the cows using a single accelerometer fixed on the neck. Another important aspect is the genericity of the developed procedure. These two issues remain a main challenge for the automatic monitoring of livestock behaviour. One potential solution would consist in combining accelerometer data with data from other sensors, like a gyrometer, a magnetometer and an altimeter, embedded in the same electronic box fixed on the neck-collar. Merging data from different signals could help to better discriminate the postures of the cows and ensure that the

methodology is applicable to any farms.

CRediT authorship contribution statement

L. Riaboff: Conceptualization, Methodology, Formal analysis, Investigation, Data curation, Writing - original draft, Writing - review & editing, Visualization. **S. Poggi:** Conceptualization, Methodology, Formal analysis, Writing - review & editing. **A. Madouasse:** Conceptualization, Writing - review & editing. **S. Couvreur:** Conceptualization, Writing - review & editing. **S. Aubin:** Conceptualization, Writing - review & editing. **N. Bédère:** Conceptualization, Writing - review & editing. **E. Goumand:** Conceptualization, Project administration. **A. Chauvin:** Conceptualization. **G. Plantier:** Conceptualization, Funding acquisition.

Declaration of Competing Interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Appendix A. Equation of the raw signal magnitude and the calculated features presented in Table 5

Equation of the raw signal magnitude

$$a_{mag} = \sqrt{a_x^2 + a_y^2 + a_z^2}$$

Equation of features

$$\bar{A}_x = \frac{1}{M} \sum_{i=1}^M a_{xi}$$

$$\sigma_x^2 = \frac{1}{M} \sum_{i=1}^M (a_{xi} - \bar{A}_x)^2$$

$$\sigma_x = \sqrt{\sigma_x^2}$$

$$Range_x = Max_x - Min_x$$

$$IQ_x = Q_{3;x} - Q_{1;x}$$

$$RMS = \sqrt{\frac{1}{M} \sum_{i=1}^M a_{xi}^2}$$

$$SMA = \frac{1}{M} (\sum_{i=1}^M |a_{xi}| + \sum_{i=1}^M |a_{yi}| + \sum_{i=1}^M |a_{zi}|)$$

$$AI = \frac{1}{M} \sum_{i=1}^M a_{mag}$$

$$MV = \frac{1}{M} (\sum_{i=1}^{M-1} |a_{x,i+1} - a_{x,i}| + \sum_{i=1}^{M-1} |a_{y,i+1} - a_{y,i}| + \sum_{i=1}^{M-1} |a_{z,i+1} - a_{z,i}|)$$

$$\beta_{1,x} = \frac{1}{M} \sum_{i=1}^M \left(\frac{a_{xi} - \bar{A}_x}{\sigma} \right)^3$$

$$\beta_{2,x} = \frac{1}{M} \sum_{i=1}^M \left(\frac{a_{xi} - \bar{A}_x}{\sigma} \right)^4$$

$$H_s = -\sum_{k=1}^N P_k \ln(P_k) \text{ with } P_k = \frac{|i_k|^2}{\sum_i |i_i|^2} \text{ and for the frequency } \lambda_k$$

$$OBDA_1 = |a_{dynamic_{amag}_i}|$$

$$OBDA_2 = |a_{dynamic_{ax}_i}| + |a_{dynamic_{ay}_i}| + |a_{dynamic_{az}_i}|$$

$$VeDBA = \sqrt{a_{dynamic_{ax}_i}^2 + a_{dynamic_{ay}_i}^2 + a_{dynamic_{az}_i}^2}$$

$$Pitch = \text{Arcsin} \left(\frac{-a_{static_y}}{\sqrt{a_{static_x}^2 + a_{static_y}^2 + a_{static_z}^2}} \right) * \frac{180}{\pi}$$

$$Roll = 2\text{Arctan} \left(\frac{a_{static_x}}{a_{static_y} + \sqrt{a_{static_y}^2 + a_{static_x}^2}} \right) * \frac{180}{\pi}$$

Normalization of features

$$c'_i = \frac{c_i - c_{min}}{c_{max} - c_{min}} \text{ where } c'_i \text{ the normalized value, } c_i \text{ is the original value, } c_{min} \text{ is the minimum value of feature } c \text{ for all observations and } c_{max} \text{ is the maximum value of feature } c \text{ for all observations}$$

Appendix B. Transition matrix T , emission matrices E and vector of probabilities π used to reassess the prediction of each Machine Learning algorithm

HMM-model is noted $\Lambda = (T, E, \pi)$. The transition matrix T , the emission matrix E and the vector of probabilities π used to reassess the predicted behaviours in this study are the following:

- The transition matrix T was obtained empirically using the data collected during the experiment. The following matrix was used:

$$T =$$

Hidden states		Instant t + 1					
		Grazing	Resting – Lying	Ruminating – Lying	Resting – Standing	Ruminating – Standing	Walking
Instant t	Grazing	0.9964	0.0001	0.0001	0.0004	0.0001	0.0029
	Resting – Lying	0.0001	0.9983	0.0013	0.0001	0.0001	0.0001
	Ruminating – Lying	0.0001	0.0041	0.9955	0.0001	0.0001	0.0001
	Resting – Standing	0.01325	0.0001	0.0001	0.97775	0.00735	0.00145
	Ruminating – Standing	0.00305	0.0001	0.0001	0.00155	0.99055	0.00465
	Walking	0.10460	0.0001	0.0001	0.02080	0.0001	0.8743

It should be noted that when the observed probability associated to one transition was zero, it was replaced by 0.0001.

- The emission matrix E corresponds to the confusion matrix from the prediction with each Machine Learning algorithm. The following matrices were used:

XGB	Prediction	Grazing	Resting – Lying	Ruminating – Lying	Resting – Standing	Ruminating – Standing	Walking
Reference	Grazing	0.993	0.000	0.000	0.000	0.000	0.007
	Resting – Lying	0.000	0.910	0.003	0.086	0.001	0.000
	Ruminating – Lying	0.0.000	0.004	0.981	0.011	0.002	0.002
	Resting – Standing	0.000	0.077	0.016	0.850	0.057	0.000
	Ruminating – Standing	0.001	0.000	0.022	0.003	0.974	0.000
	Walking	0.003	0.000	0.000	0.000	0.000	0.997

SVM	Prediction	Grazing	Resting – Lying	Ruminating – Lying	Resting – Standing	Ruminating – Standing	Walking
Reference	Grazing	0.989	0.000	0.001	0.000	0.001	0.010
	Resting – Lying	0.008	0.874	0.022	0.086	0.004	0.006
	Ruminating – Lying	0.000	0.007	0.972	0.007	0.012	0.002
	Resting – Standing	0.000	0.139	0.017	0.797	0.044	0.003
	Ruminating – Standing	0.000	0.000	0.041	0.003	0.951	0.004
	Walking	0.023	0.000	0.004	0.000	0.010	0.963

ADA	Prediction	Grazing	Resting – Lying	Ruminating – Lying	Resting – Standing	Ruminating – Standing	Walking
Reference	Grazing	0.992	0.000	0.000	0.000	0.000	0.008
	Resting – Lying	0.000	0.811	0.032	0.145	0.012	0.001
	Ruminating – Lying	0.000	0.009	0.967	0.005	0.015	0.003
	Resting – Standing	0.000	0.303	0.015	0.636	0.045	0.001
	Ruminating – Standing	0.001	0.000	0.070	0.008	0.920	0.001
	Walking	0.014	0.000	0.023	0.000	0.007	0.956

RF	Prediction	Grazing	Resting – Lying	Ruminating – Lying	Resting – Standing	Ruminating – Standing	Walking
Reference	Grazing	0.992	0.000	0.000	0.000	0.000	0.008
	Resting – Lying	0.000	0.878	0.010	0.111	0.001	0.000
	Ruminating – Lying	0.000	0.002	0.981	0.009	0.006	0.002
	Resting – Standing	0.000	0.103	0.017	0.824	0.055	0.001
	Ruminating – Standing	0.000	0.000	0.044	0.002	0.954	0.000
	Walking	0.007	0.000	0.005	0.000	0.000	0.988

In these matrices, the true behaviours are in rows and the predicted behaviours in columns. Each occurrence in the confusion matrix was expressed as a percentage of the total number of occurrences of the corresponding row. In this way, the sum of each row was equal to 1.

- The vector π was obtained empirically using the experimental data. The following vector was obtained:

$$\pi =$$

Hidden states	Grazing	Resting – Lying	Ruminating – Lying	Resting – Standing	Ruminating – Standing	Walking
Initial probabilities	0.5289	0.1607	0.1627	0.0622	0.0635	0.0219

Appendix C. Definition of the HMM algorithm

A HMM-model is noted $\Lambda = (T, E, \pi)$ and based on:

- Its hidden states which constitute the ensemble $S = \{s_1, s_2, \dots, s_n\}$ where n is the number of hidden states. The state where is the HMM at the instant t is noted q_t ($q_t \in S$).
- m observable symbols in each state. All the possible observations constitute the ensemble $V = \{v_1, v_2, \dots, v_m\}$. $O_t \in V$ is the observed symbol at the instant t .
- A matrix of transition probabilities between states, noted T and defined as follows:
 $T(i, j) = P(q_{t+1} = s_j | q_t = s_i) \forall i, j \in \{1, \dots, n\}$ and $\forall t \in \{1, \dots, T\}$ with:
 $T(i, j) > 0 \forall i, j$ and $\sum_{j=1}^n T(i, j) = 1$
- A matrix of probabilities of observation of each symbol in each state, called emission probability and noted E . This matrix is defined as follows:
 $E(j, k) = P(O_t = v_k | q_t = s_j) \forall j \in \{1, \dots, n\}$ and $\forall k \in \{1, \dots, m\}$ with:
 $E(j, k) > 0$ and $\sum_{k=1}^m E(j, k) = 1$
- A vector π of initial probabilities: $\pi = \{\pi_1, \pi_2, \dots, \pi_n\}$ where for each state i , π_i is the probability that the initial state of the HMM was i :
 $\pi_i = P(q_1 = s_i) \forall i \in \{1, \dots, n\}$ with $\pi_i > 0 \forall i$ and $\sum_{i=1}^n \pi_i = 1$

Once the three parameters (T, E, π) of the HMM were determined, the optimal sequence of hidden states, *i.e.*, the most probable hidden states given a sequence of observations, is obtained with the Viterbi algorithm.

Appendix D. Performance metrics used to assess the models

$$accuracy = \frac{\text{number of well classified instances}}{\text{number of instances}}$$

$$\text{Cohen's Kappa} = \frac{p_o - p_e}{1 - p_e}$$

$$sensitivity_i = \frac{TP_i}{TP_i + FN_i}$$

$$specificity_i = \frac{TN_i}{FP_i + TN_i}$$

where p_o is the relative observed agreement among raters and p_e is the hypothetical probability of chance agreement. The index i is the considered behaviour; TP_i (True positives) is the number of instances where behaviour i was observed and correctly predicted; FN_i (False negatives) is the number of instances where behaviour i was observed but another behaviour was predicted, FP_i (False positives) is the number of instances where behaviour i was predicted but another behaviour was observed; TN_i (True negatives) is the number of instances where behaviour i was not observed and not predicted.

Appendix E. Confusion matrices obtained with every model using the test dataset before the HMM-based Viterbi smoothing

XGB	Prediction	Grazing	Resting – Lying	Ruminating – Lying	Resting – Standing	Ruminating – Standing	Walking
Reference	Grazing	16,513	0	0	0	0	118
	Resting – Lying	0	2857	10	269	4	1
	Ruminating – Lying	0	25	5663	64	12	11
	Resting – Standing	0	96	20	1057	71	0
	Ruminating – Standing	3	0	46	6	2052	0
	Walking	2	0	0	0	0	571

SVM	Prediction	Grazing	Resting – Lying	Ruminating – Lying	Resting – Standing	Ruminating – Standing	Walking
Reference	Grazing	16,479	0	11	0	10	163
	Resting – Lying	26	2751	68	271	12	20
	Ruminating – Lying	0	39	5549	38	69	13
	Resting – Standing	0	188	23	1080	60	4
	Ruminating – Standing	1	0	86	7	1983	9
	Walking	12	0	2	0	5	492

ADA	Prediction	Grazing	Resting – Lying	Ruminating – Lying	Resting – Standing	Ruminating – Standing	Walking
Reference	Grazing	16,508	0	0	0	0	131
	Resting – Lying	0	2501	99	446	36	3
	Ruminating – Lying	0	48	5458	31	87	18
	Resting – Standing	0	429	21	901	64	1
	Ruminating – Standing	2	0	148	18	1948	2
	Walking	8	0	13	0	4	546

RF	Prediction	Grazing	Resting – Lying	Ruminating – Lying	Resting – Standing	Ruminating – Standing	Walking
Reference	Grazing	16,514	0	0	0	0	131
	Resting – Lying	0	2844	33	359	3	1
	Ruminating – Lying	0	11	5589	51	35	11
	Resting – Standing	0	123	20	981	66	1
	Ruminating – Standing	0	0	94	5	2035	0
	Walking	4	0	3	0	0	557

Appendix F. Confusion matrices obtained with every model using the test dataset after the HMM-based Viterbi smoothing

XGB	Prediction	Grazing	Resting – Lying	Ruminating – Lying	Resting – Standing	Ruminating – Standing	Walking
Reference	Grazing	16,514	0	0	0	0	103
	Resting – Lying	0	2840	5	237	0	0
	Ruminating – Lying	0	16	5666	62	5	11
	Resting – Standing	0	122	25	1088	74	1
	Ruminating – Standing	2	0	43	9	2060	0
	Walking	2	0	0	0	0	586

SVM	Prediction	Grazing	Resting – Lying	Ruminating – Lying	Resting – Standing	Ruminating – Standing	Walking
Reference	Grazing	16,480	0	10	0	10	154
	Resting – Lying	24	2768	59	204	9	19
	Ruminating – Lying	0	32	5573	36	53	15
	Resting – Standing	0	178	22	1149	61	3
	Ruminating – Standing	1	0	75	7	2001	9
	Walking	13	0	0	0	0	501

ADA	Prediction	Grazing	Resting – Lying	Ruminating – Lying	Resting – Standing	Ruminating – Standing	Walking
Reference	Grazing	16,510	0	0	0	0	127
	Resting – Lying	0	2487	68	406	20	2
	Ruminating – Lying	0	39	5521	24	69	22
	Resting – Standing	6	452	16	942	79	1
	Ruminating – Standing	2	0	122	24	1971	0
	Walking	0	0	12	0	0	549

RF	Prediction	Grazing	Resting – Lying	Ruminating – Lying	Resting – Standing	Ruminating – Standing	Walking
Reference	Grazing	16,514	0	0	0	0	128
	Resting – Lying	0	2820	23	295	0	0
	Ruminating – Lying	0	9	5604	46	29	11
	Resting – Standing	0	149	25	1048	64	2
	Ruminating – Standing	0	0	84	7	2046	0
	Walking	4	0	3	0	0	560

References

- Alfaro, E., Gámez, M., García, N., 2013. adabag: An R package for classification with boosting and bagging. *J. Stat. Softw.* 54, 1–35. <https://doi.org/10.18637/jss.v054.i02>.
- Alvarenga, F.A.P., Borges, I., Palkovič, L., Rodina, J., Oddy, V.H., Dobos, R.C., 2016. Using a three-axis accelerometer to identify and classify sheep behaviour at pasture. *Appl. Anim. Behav. Sci.* 181, 91–99. <https://doi.org/10.1016/j.applanim.2016.05.026>.
- Andriamandroso, A.L.H., 2017. Cattle grazing dynamics under contrasted pasture characteristics at temporal and spatial scales (Sciences agronomiques et ingénierie biologique). Université de Liège, Gembloux Agro-Bio Tech, Liège, Belgique.
- Barker, Z.E., Vázquez Diosdado, J.A., Codling, E.A., Bell, N.J., Hodges, H.R., Croft, D.P., Amory, J.R., 2018. Use of novel sensors combining local positioning and acceleration to measure feeding behavior differences associated with lameness in dairy cattle. *J. Dairy Sci.* 101, 6310–6321. <https://doi.org/10.3168/jds.2016-12172>.
- Barwick, J., Lamb, D.W., Dobos, R., Welch, M., Trotter, M., 2018. Categorising sheep activity using a tri-axial accelerometer. *Comput. Electron. Agric.* 145, 289–297. <https://doi.org/10.1016/j.compag.2018.01.007>.
- Benaissa, S., Tuytens, F.A.M., Plets, D., Cattrysse, H., Martens, L., Vandaele, L., Joseph, W., Sonck, B., 2018. Classification of ingestive-related cow behaviours using RumiWatch halter and neck-mounted accelerometers. *Appl. Anim. Behav. Sci.* <https://doi.org/10.1016/j.applanim.2018.12.003>.

- Benaissa, S., Tuytens, F.A.M., Plets, D., de Pessemier, T., Trogh, J., Tanghe, E., Martens, L., Vandaele, L., Van Nuffel, A., Joseph, W., Sonck, B., 2017. On the use of on-cow accelerometers for the classification of behaviours in dairy barns. *Res. Vet. Sci.* <https://doi.org/10.1016/j.rvsc.2017.10.005>.
- Bersch, S., Azzi, D., Khushainov, R., Achumba, I., Ries, J., 2014. Sensor Data Acquisition and Processing Parameters for Human Activity Classification. *Sensors* 14, 4239–4270. <https://doi.org/10.3390/s140304239>.
- Breiman, L., 2001. Random forests. *Mach. Learn.* 45, 5–32.
- Burges, C.J.C., 1998. A tutorial on support vector machines for pattern recognition. *Data Min. Knowl. Discov.* 2, 121–167.
- Burow, E., Rousing, T., Thomsen, P.T., Otten, N.D., Sørensen, J.T., 2013. Effect of grazing on the cow welfare of dairy herds evaluated by a multidimensional welfare index. *Animal* 7, 834–842. <https://doi.org/10.1017/S1751731112002297>.
- Carvalho, P.C.F., 2013. Harry Stobbs memorial lecture: can grazing behavior support innovations in grassland management? *Trop. Grassl.* 1, 137–155.
- Chapinal, N., de Passillé, A.M., Weary, D.M., von Keyserlingk, A.G., Rushen, J., 2009. Using gait score, walking speed, and lying behavior to detect hoof lesions in dairy cows. *J. Dairy Sci.* <https://doi.org/10.3168/jds.2009-2115>.
- Chen, T., He, T., Benesty, M., Khotilovich, V., Tang, Y., Cho, H., Chen, K., Mitchell, R., Cano, I., Zhou, T., Li, M., Xie, J., Lin, M., Geng, Y., Li, Y., 2018. xgboost: Extreme Gradient Boosting.
- Cohen, J., 1960. A coefficient of agreement for nominal scales. *Educ. Psychol. Meas.* 20, 37–46. <https://doi.org/10.1177/001316446002000104>.
- Dutta, R., Smith, D., Rawnsley, R., Bishop-Hurley, G., Hills, J., Timms, G., Henry, D., 2015. Dynamic cattle behavioural classification using supervised ensemble classifiers. *Comput. Electron. Agric.* 18–28. <https://doi.org/10.1016/j.compag.2014.12.002>.
- Farm Animal Welfare Committee (FAWC) [WWW Document], 2011. URL <https://www.gov.uk/government/groups/farm-animal-welfare-committee-fawc>.
- Fida, B., Bernabucci, I., Bibbo, D., Conforto, S., Schmid, M., 2015. Pre-processing effect on the accuracy of event-based activity segmentation and classification through inertial sensors. *Sensors* 15, 23095–23109. <https://doi.org/10.3390/s150923095>.
- Figo, D., Diniz, P.C., Ferreira, D.R., Cardoso, J.M.P., 2010. Preprocessing techniques for context recognition from accelerometer data. *Pers. Ubiquitous Comput.* 14, 645–662. <https://doi.org/10.1007/s00779-010-0293-9>.
- Forney, G.D., 1973. The Viterbi algorithm. *Proc. IEEE* 61, 268–278.
- Friedman, J.H., 2001. Greedy function approximation: a gradient boosting machine. *Ann. Stat.* 29, 1189–1232.
- Fulkerson, W.J., McKean, K., Nandra, K.S., Barchia, I.M., 2005. Benefits of accurately allocating feed on a daily basis to dairy cows grazing pasture. *Aust. J. Exp. Agric.* 45, 331. <https://doi.org/10.1071/EA03109>.
- Giovanetti, V., Decandia, M., Molle, G., Acciaro, M., Mameli, M., Cabiddu, A., Cossu, R., Serra, M.G., Manca, C., Rassu, S.P.G., Dimairo, C., 2017. Automatic classification system for grazing, ruminating and resting behaviour of dairy sheep using a tri-axial accelerometer. *Livest. Sci.* 196, 42–48. <https://doi.org/10.1016/j.livsci.2016.12.011>.
- Gonzalez, L.A., Bishop-Hurley, G.J., Handcock, R.N., Crossman, C., 2015. Behavioral classification of data from collars containing motion sensors in grazing cattle. *Comput. Electron. Agric.* 91–102. <https://doi.org/10.1016/j.compag.2014.10.018>.
- Hamalainen, W., Jarvinen, M., Martiskainen, P., Mononen, J., 2011. Jerk-based feature extraction for robust activity recognition from acceleration data. In: 2011 11th International Conference on Intelligent Systems Design and Applications. Presented at the 2011 11th International Conference on Intelligent Systems Design and Applications (ISDA), pp. 831–836. <https://doi.org/10.1109/ISDA.2011.6121760>.
- Himmelmann, L., 2010. HMM: HMM – Hidden Markov Models.
- Kamphuis, C., Delarue, B., Burke, C.R., Jago, J., 2012. Field evaluation of 2 collar-mounted activity meters for detecting cows in estrus on a large pasture-grazed dairy farm. *J. Dairy Sci.* 95, 3045–3056. <https://doi.org/10.3168/jds.2011-4934>.
- Karatzoglou, A., Smola, A., Hornik, K., Zeileis, A., 2004. kernlab – An S4 Package for Kernel Methods in R. *J. Stat. Softw.* 11, 1–20. <https://doi.org/10.18637/jss.v011.i09>.
- Kuhn, M., Wing, J., Weston, S., Williams, A., Keefer, C., Engelhardt, A., Cooper, T., Mayer, Z., Kenkel, B., Benesty, M., Lescarbeau, R., Ziem, A., Scrucca, L., Tang, Y., Candan, C., Hunt, T., 2018. caret: Classification and Regression Training.
- Liaw, A., Wiener, M., 2002. Classification and Regression by randomForest. *R News* 2, 18–22. <https://CRAN.R-project.org/doc/Rnews/>.
- Lush, L., Wilson, R.P., Holton, M.D., Hopkins, P., Marsden, K.A., Chadwick, D.R., King, A.J., 2018. Classification of sheep urination events using accelerometers to aid improved measurements of livestock contributions to nitrous oxide emissions. *Comput. Electron. Agric.* 150, 170–177. <https://doi.org/10.1016/j.compag.2018.04.018>.
- Martiskainen, P., Jarvinen, M., Skön, J.P., Tiirikainen, J., Kolehmainen, M., Mononen, J., 2009. Cow behaviour pattern recognition using a three-dimensional accelerometer and support vector machines. *Appl. Anim. Behav. Sci.* 119, 32–38.
- Mathie, M.J., Coster, A.C.F., Lovell, N.H., Celler, B.G., 2004. Accelerometry: providing an integrated, practical method for long-term, ambulatory monitoring of human movement. *Physiol. Meas.* 25, R1–R20. <https://doi.org/10.1088/0967-3334/25/2/R01>.
- McSweeney, D., Foley, C., Halton, P., O'Brien, B., 2015. Calibration of an automated grass measurement tool to enhance the precision of grass measurement in pasture based farming systems. In: Teagasc Ag Conference.
- Norring, M., Häggman, J., Simojoki, H., Tamminen, P., Winckler, C., Pastell, M., 2014. Short communication: Lameness impairs feeding behavior of dairy cows. *J. Dairy Sci.* 97, 4317–4321. <https://doi.org/10.3168/jds.2013-7512>.
- O'Driscoll, K., Lewis, E., Kennedy, E., 2019. Effect of feed allowance at pasture on the lying behaviour of dairy cows. *Appl. Anim. Behav. Sci.* 213, 40–46. <https://doi.org/10.1016/j.applanim.2019.02.002>.
- Penning, P.D., 1983. A technique to record automatically some aspects of grazing and ruminating behaviour in sheep. *Grass Forage Sci.* 38, 89–96. <https://doi.org/10.1111/j.1365-2494.1983.tb01626.x>.
- R Core Team, 2019. R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria.
- Rahman, A., Smith, D.V., Little, B., Ingham, A.B., Greenwood, P.L., Bishop-Hurley, G.J., 2018. Cattle behaviour classification from collar, halter, and ear tag sensors. *Inf. Process. Agric.* 5, 124–133. <https://doi.org/10.1016/j.inpa.2017.10.001>.
- Riaboff, L., Aubin, S., Bédère, N., Couvreur, S., Madouasse, A., Goumand, E., Chauvin, A., Plantier, G., 2019. Evaluation of pre-processing methods for the prediction of cattle behaviour from accelerometer data. *Comput. Electron. Agric.* 165, 104961. <https://doi.org/10.1016/j.compag.2019.104961>.
- Riaboff, L., Bedere, N., Couvreur, S., Aubin, S., Goumand, E., Magnier, J., Madouasse, A., Chauvin, A., Plantier, G., 2018. Influence of pasture characteristics and time of day on dairy cow behaviour predicted from GPS-data. In: 7 Gen Meet. Eur. Grassl. Fed. EGF 23, pp. 803–809.
- Robert, B., White, B.J., Renter, D.G., Larson, R.L., 2009. Evaluation of three-dimensional accelerometers to monitor and classify behavior patterns in cattle. *Comput. Electron. Agric.* 67, 80–84.
- Rushen, J., Chapinal, N., de Passillé, A., 2012. Automated monitoring of behavioural-based animal welfare indicators. *Anim. Welf.* 21, 339–350. <https://doi.org/10.7120/09627286.21.3.339>.
- Rutten, C.J., Velthuis, A.G.J., Steeneveld, W., Hogeveen, H., 2013. Sensors to support health management on dairy farms. *J. Dairy Sci.* 1928–1952.
- Schlecht, E., Dickhoefer, U., Gumpertsberger, E., Buerkert, A., 2009. Grazing itineraries and forage selection of goats in the Al Jabal al Akhdar mountain range of northern Oman. *J. Arid Environ.* 73, 355–363. <https://doi.org/10.1016/j.jaridenv.2008.10.013>.
- Schütz, K.E., Rogers, A.R., Poulouin, Y.A., Cox, N.R., Tucker, C.B., 2010. The amount of shade influences the behavior and physiology of dairy cattle. *J. Dairy Sci.* 93, 9.
- Shahriar, M.D.S., Smith, D., Rahman, A., Freeman, M., Hills, J., Rawnsley, R., Henry, D., Bishop-Hurley, G., 2016. Detecting heat events in dairy cows using accelerometers and unsupervised learning. *Comput. Electron. Agric.* 128, 20–26. <https://doi.org/10.1016/j.compag.2016.08.009>.
- Shi, H., Wang, H., Huang, Y., Zhao, L., Qin, C., Liu, C., 2019. A hierarchical method based on weighted extreme gradient boosting in ECG heartbeat classification. *Comput. Methods Programs Biomed.* 171, 1–10. <https://doi.org/10.1016/j.cmpb.2019.02.005>.
- Smith, D., Rahman, A., Bishop-Hurley, G.J., Hills, J., Shahriar, S., Henry, D., Rawnsley, R., 2016. Behavior classification of cows fitted with motion collars: Decomposing multi-class classification into a set of binary problems. *Comput. Electron. Agric.* 131, 40–50. <https://doi.org/10.1016/j.compag.2016.10.006>.
- Subasi, A., Dammam, D.H., Alghamdi, R.D., Makawi, R.A., Albiety, E.A., Brahimi, T., Sarirete, A., 2018. Sensor based human activity recognition using adaboost ensemble classifier. *Procedia Comput. Sci.* 140, 104–111. <https://doi.org/10.1016/j.procs.2018.10.298>.
- Vázquez Diosdado, J.A., Barker, Z.E., Hodges, H.R., Amory, J.R., Croft, D.P., Bell, N.J., Codling, E.A., 2015. Classification of behaviour in housed dairy cows using an accelerometer-based activity monitoring system. *Anim. Biotelemet.* 3. <https://doi.org/10.1186/s40317-015-0045-8>.
- Walker, J.S., Jones, M.W., Laramee, R.S., Holton, M.D., Shepard, E.L., Williams, H.J., Scantlebury, D.M., Marks, N., Magowan, E.A., Maguire, I.E., Bidder, O.R., Di Virgilio, A., Wilson, R.P., 2015. Prying into the intimate secrets of animal lives; software beyond hardware for comprehensive annotation in 'Daily Diary' tags. *Mov. Ecol.* 3. <https://doi.org/10.1186/s40462-015-0056-3>.
- Werner, J., Umstatter, C., Kennedy, E., Grant, J., Leso, L., Geoghegan, A., Shalloo, L., Schick, M., O'Brien, B., 2019. Identification of possible cow grazing behaviour indicators for restricted grass availability in a pasture-based spring calving dairy system. *Livest. Sci.* 220, 74–82. <https://doi.org/10.1016/j.livsci.2018.12.004>.
- Willshire, J.A., Bell, N.J., 2009. An economic review of cattle lameness. *Cattle Pract.* 17, 136–141.
- Wilson, R., Shepard, E., Liebsch, N., 2008. Prying into the intimate details of animal lives: use of a daily diary on animals. *Endanger. Species Res.* 4, 123–137. <https://doi.org/10.3354/esr00064>.
- Witten, I.H., Frank, E., 2011. *Data Mining: Practical Machine Learning Tools and Techniques*. Elsevier <https://doi.org/10.1016/C2009-0-19715-5>.
- Yang, J., 2009. Toward physical activity diary: motion recognition using simple acceleration features with mobile phones. In: *Proceedings of the 1st International Workshop on Interactive Multimedia for Consumer Electronics*, pp. 1–10.
- Yunta, C., Guasch, I., Bach, A., 2012. Short communication: Lying behavior of lactating dairy cows is influenced by lameness especially around feeding time. *J. Dairy Sci.* 95, 6546–6549. <https://doi.org/10.3168/jds.2012-5670>.
- Zaccarelli, N., Li, B.-L., Petrosillo, I., Zurlini, G., 2013. Order and disorder in ecological time-series: Introducing normalized spectral entropy. *Ecol. Indic.* 28, 22–30. <https://doi.org/10.1016/j.ecolind.2011.07.008>.

Chapitre 5 : Relation entre le comportement des vaches laitières et les caractéristiques de la prairie explorée *via* une méthodologie basée sur des données GPS et accéléromètres en vue de souligner le potentiel de l'approche pour le suivi du bien-être animal.

1. Contexte de l'étude

Les outils numériques permettant d'aider l'éleveur dans sa prise de décision pour la rotation des parcelles, ou encore pour surveiller le bien-être des vaches laitières au pâturage, restent pour l'instant marginaux et de plus-value discutable (Dolecheck et al., 2013). Parmi les freins majeurs au développement de ces outils, on peut noter la difficulté de prédire un large spectre de comportements de façon robuste (Rushen et al., 2012). Il est en effet primordial de pouvoir remonter l'ensemble des comportements principaux afin d'envisager les applications souhaitées puisque des modifications sont susceptibles d'avoir lieu sur plusieurs d'entre eux en cas de ressource limitante sur la prairie (Werner et al., 2019) ou en cas de troubles de santé ou de confort (Schütz et al., 2010; Siivonen et al., 2011). La combinaison des comportements avec la position des vaches laitières, comme proposée par Andriamandroso (2017), constitue également une approche prometteuse puisque l'utilisation des sites par les animaux diffère selon l'état de la ressource et les conditions climatiques (Putfarken et al., 2008).

Le cadre méthodologique développé dans l'étude précédente assure une prédiction satisfaisante de chacun des comportements principaux des vaches laitières au pâturage, incluant comportement alimentaire, comportement statique avec distinction des postures et déplacement. Les comportements prédits peuvent également être couplés avec les données GPS en vue de les géolocaliser. Cette approche devrait donc être pertinente pour détecter des changements de comportement sur les prairies en lien avec les conditions de pâturage et l'environnement direct des animaux (état de la ressource, conditions climatiques, présence d'animaux extérieurs au troupeau, etc.).

2. Objectifs

Cette étude a pour objectif d'illustrer le potentiel d'une prédiction automatique des comportements des vaches laitières au pâturage couplée à la position dans la parcelle en vue de

répondre à l'une des applications souhaitées, à savoir le suivi automatisé du bien-être des animaux au pâturage.

3. Stratégie

Afin d'évaluer l'intérêt du cadre méthodologique couplé à la position pour la détection d'un changement de comportements en lien avec les conditions de pâturage, il semble pertinent dans un premier temps de relier les comportements exprimés avec les caractéristiques des prairies et l'environnement direct des animaux en absence de stress quelconque, et de s'assurer de la cohérence des résultats obtenus. En supposant que les liens établis soient en phase avec la littérature sur le comportement et sur les stratégies alimentaires des vaches laitières au pâturage, l'approche développée pourrait par la suite être envisagée pour détecter les changements propres à certaines situations (ressource limitante, stress physique, stress thermique, etc.).

4. Démarche

La démarche mise en œuvre est illustrée dans la Figure 16. Le cadre méthodologique établi lors de l'étude précédente a été mis en œuvre pour prédire les comportements des 26 vaches laitières issues d'un des 4 élevages pendant les 5 jours de pâturage (cf. chapitre 2) sur chacune des fenêtres de 10 secondes. La position des animaux obtenue avec les données GPS a été couplée aux comportements prédits (**comportements géolocalisés**). Un découpage des parcelles en zones de même surface (8 m * 8 m) a ensuite été réalisé. Le temps passé à réaliser chacun des comportements dans chaque zone a été calculé pour chaque animal et pour chaque jour de pâturage. Les zones ont ensuite été caractérisées à partir des éléments identifiés sur les prairies (éléments structurants, humidité du sol, pente, caractéristiques botaniques, présence du bâtiment, des génisses, etc.). Le temps passé en moyenne à réaliser chacun des six comportements, par vache et par jour, dans chaque type de zones a finalement été exprimé en fonction des caractéristiques de la prairie. Un modèle linéaire mixte et une analyse de la variance ont été mis en œuvre pour estimer les effets de chacune des caractéristiques sur le comportement des vaches laitières et leur niveau de significativité.

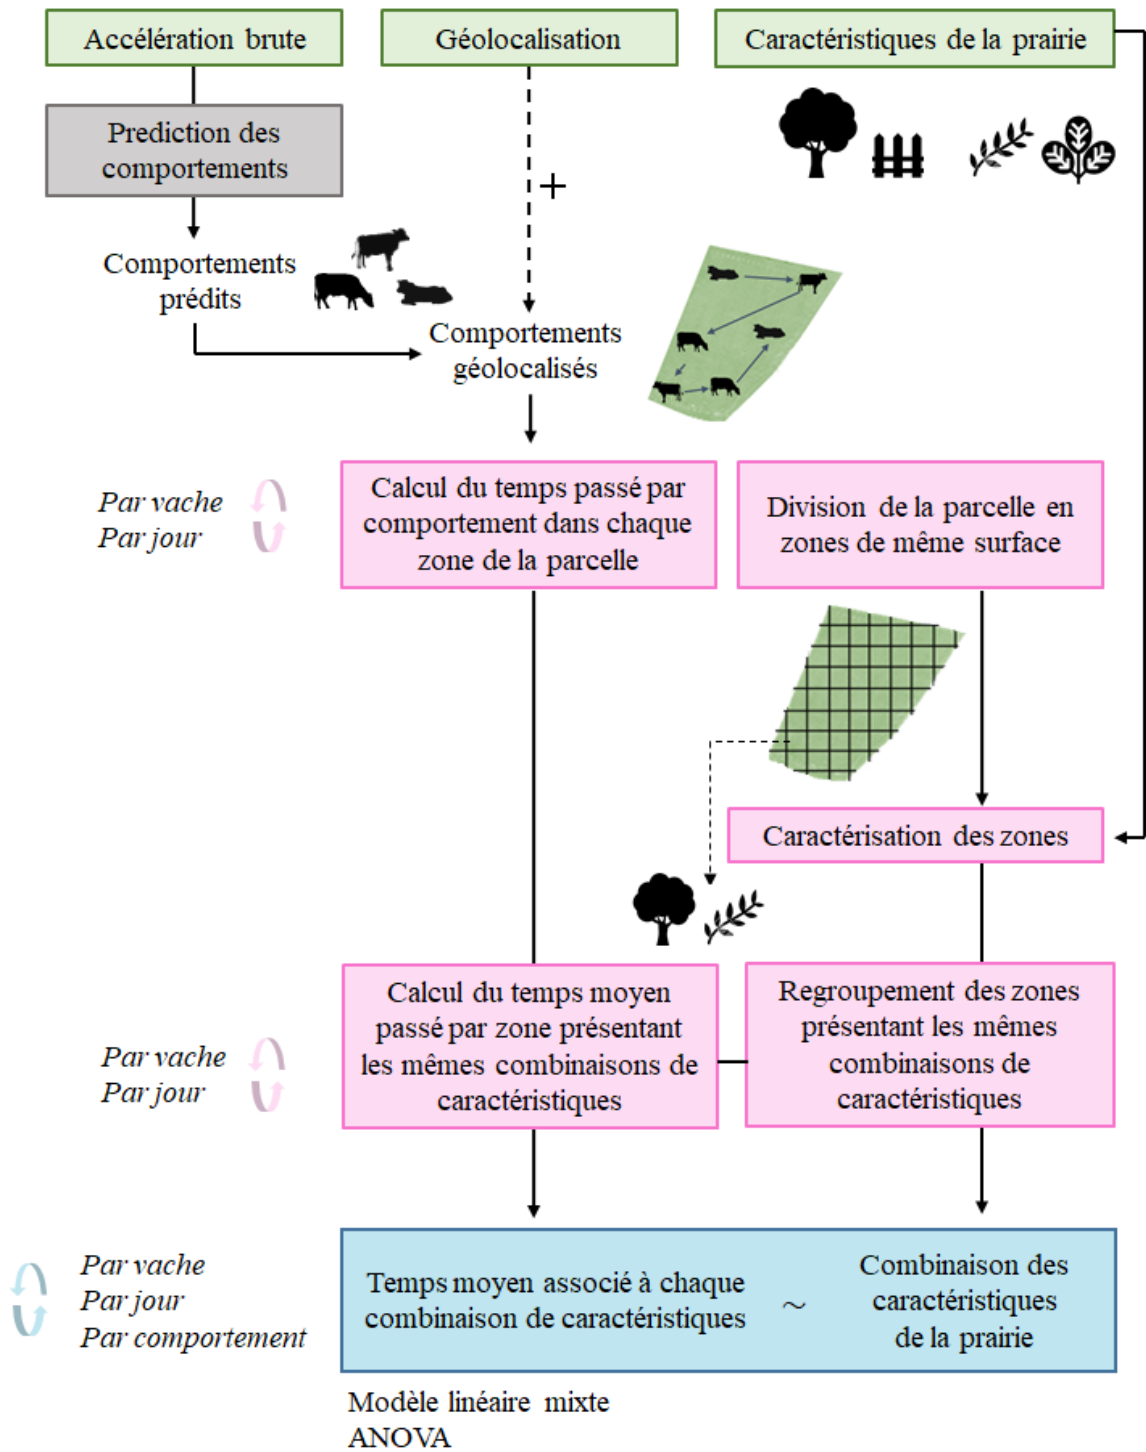


Figure 16. Démarche mise en œuvre pour souligner le potentiel de l'approche pour le suivi du bien-être des animaux en lien avec les conditions de pâturage et l'environnement extérieur.

5. Résultats

Les disparités de structure et de composition floristique des deux prairies pâturées ont conduit à une organisation différente du comportement des vaches laitières. Une organisation prononcée autour des éléments structurants a été observée dans la prairie permanente ($P < 0.001$). En particulier, les zones à proximité des arbres ont été significativement privilégiées pour les comportements de repos ($P < 0.001$) et de rumination ($P < 0.001$) tandis que des zones riches en houlque laineuse ont été préférentiellement pâturées ($P < 0.001$), au même titre que celles à proximité d'une source d'eau ($P < 0.001$). Au contraire, les zones marécageuses ont été rejetées quel que soit le comportement exprimé ($P < 0.01$). Dans la prairie temporaire, l'organisation des vaches laitières a surtout été influencée par les éléments extérieurs à la parcelle. La proximité des génisses ($P < 0.05$) ou du robot de traite ($P < 0.05$) a notamment eu un effet majeur sur l'organisation des bovins. Des études sur l'utilisation des zones d'ombre (Schütz et al., 2010) et points d'eau (Batista et al., 2019), sur les stratégies alimentaires (Rook et al., 2004; Rutter et al., 2004) ou encore sur le comportement grégaire des vaches laitières (Arave and Albright, 1981) ont permis d'appuyer l'ensemble des résultats obtenus.

MESSAGE A RETENIR

Le cadre méthodologique mis en place dans l'étude précédente combiné à la position des vaches laitières a permis de mettre en lien le comportement avec les caractéristiques de la prairie de façon cohérente au regard de l'existant. Cette approche devrait donc être pertinente pour observer des changements de comportement en lien avec les conditions de pâturage et l'environnement direct des animaux, en vue de mieux appréhender des évènements stressants sur les prairies par la suite.

6. Valorisation

Ce travail a donné lieu à un article soumis en Février 2020 au journal *Biosystems Engineering*.

Riaboff L., Couvreur S., Madouasse A., Aubin S., Massabie P., Chauvin A., Bédère N. and Plantier G., 2020. Relationship between dairy cow behaviour and pasture characteristics explored with a methodology based on accelerometer and GPS data to highlight its potential for animal welfare monitoring. *Biosystems Engineering (submitted)*.

Références

- Arave, C.W., Albright, J.L., 1981. Cattle behaviour. *J. Dairy Sci.* 64, 1318–1329.
- Batista, P.H.D., Almeida, G.L.P.D., Sarmento, R.M., Pandorfi, H., Melo, A.A.S.D., Rolim, M.M., Medeiros, V.W.C.D., Gonçalves, G.E., 2019. Monitoring the bovine activity in grazing by an electronic sensing device based on GPS. *Rev. Ciênc. Agrár.* vol. 42 n.º 2 (2019)-. <https://doi.org/10.19084/rca.17264>
- Dolecheck, K.A., Heersche, G., Bewley, J.M., 2013. Investment analysis of automated estrus detection technologies. Presented at the Proceedings of the precision dairy conference and expo., University of Minnesota, Mayo Civic Center, Rochester, Minnesota, pp. 103–104.
- Putfarken, D., Dengler, J., Lehmann, S., Härdtle, W., 2008. Site use of grazing cattle and sheep in a large-scale pasture landscape: A GPS/GIS assessment. *Appl. Anim. Behav. Sci.* 111, 54–67. <https://doi.org/10.1016/j.applanim.2007.05.012>
- Rook, A.J., Harvey, A., Parsons, A.J., Orr, R.J., Rutter, S.M., 2004. Bite dimensions and grazing movements by sheep and cattle grazing homogeneous perennial ryegrass swards. *Appl. Anim. Behav. Sci.* 88, 227–242. <https://doi.org/10.1016/j.applanim.2004.03.006>
- Rushen, J., Chapinal, N., de Passillé, A., 2012. Automated monitoring of behavioural-based animal welfare indicators. *Anim. Welf.* 21, 339–350. <https://doi.org/10.7120/09627286.21.3.339>
- Rutter, S.M., Orr, R.J., Yarrow, N.H., Champion, R.A., 2004. Dietary Preference of Dairy Cows Grazing Ryegrass and White Clover. *J. Dairy Sci.* 87, 1317–1324. [https://doi.org/10.3168/jds.S0022-0302\(04\)73281-6](https://doi.org/10.3168/jds.S0022-0302(04)73281-6)
- Schütz, K.E., Rogers, A.R., Poulouin, Y.A., Cox, N.R., Tucker, C.B., 2010. The amount of shade influences the behavior and physiology of dairy cattle. *J. Dairy Sci.* 93, 125–33.
- Siivonen, J., Taponen, S., Hovinen, M., Pastell, M., Lensink, B.J., Pyörälä, S., Hänninen, L., 2011. Impact of acute clinical mastitis on cow behaviour. *Appl. Anim. Behav. Sci.* 132, 101–106. <https://doi.org/10.1016/j.applanim.2011.04.005>
- Werner, J., Umstatter, C., Kennedy, E., Grant, J., Leso, L., Geoghegan, A., Shalloo, L., Schick, M., O'Brien, B., 2019. Identification of possible cow grazing behaviour indicators for restricted grass availability in a pasture-based spring calving dairy system. *Livest. Sci.* 220, 74–82. <https://doi.org/10.1016/j.livsci.2018.12.004>

Title

Relationship between dairy cow behaviour and pasture characteristics explored with a methodology based on accelerometer and GPS data to highlight its potential for animal welfare monitoring.

Abstract

Our aim in this study was to investigate whether the behaviours of dairy cows at pasture predicted with accelerometer data and combined with GPS data can be used to relate the expressed behaviours to pasture characteristics. This would highlight the potential of this approach to assess welfare status of dairy cows associated to grazing conditions. During spring 2018, 26 Holstein cows were equipped with a three-dimensional accelerometer and GPS sensor fixed on a neck-collar for five days of grazing. Cows grazed in a permanent and temporary grassland alternately. Pasture characteristics (trees, hedges and boundaries), soil moisture, level of the slope and botanical characteristics were assigned in each zone of the pastures. Behaviours of dairy cows were predicted using accelerometer data and combined with the Global Positioning System data to get the time-budgets expressed in each zone. The relation between time-budgets and pasture characteristics was explored using a linear mixed model. In the permanent grassland, dairy cows spent more time under the trees to ruminate ($P < 0.001$) and to rest ($P < 0.001$) and more time to graze in areas with *Holcus lanatus* ($P < 0.001$). In the temporary grassland, the behaviour was influenced by the external environment (presence of other animals on the farm; $P < 0.05$). Thus, the welfare status of the cows in relation to grazing conditions could be assessed using this approach. It could be implemented into an integrative tool for pasture-based systems (oestrus detection, health and welfare monitoring, recommendations to the farmer, etc.).

Keywords

Predicted behaviours; dairy cows; pasture characteristics; three-dimensional accelerometer; Global Positioning System; animal welfare monitoring.

1. Introduction

Several benefits are often associated to pasture-based milk production systems in comparison with indoor-feeding systems, as greater profitability (Hofstetter et al., 2014) and more environmentally friendly (O'Brien et al., 2012). Furthermore, pasture-based systems benefit from a very favourable image from consumers as they directly associate pasture with animal welfare and healthy state (Cardoso et al., 2016). However, this perspective is not always consistent as some studies showed that welfare and health status of dairy cows depend mainly on the grazing conditions. For instance, insufficient pasture resources lead to competitive grazing situation during which the aggressive behaviour of the dominant cows is more pronounced (Phillips and Rind, 2002). Soil moisture in the paddocks during wet months also make the claws softer and more prone to injuries (Vermunt and Greenough, 1995), leading to an increase of lameness at pasture (Ranjbar et al., 2016). When the temperature and the solar radiations increase, the lack of shaded areas in the paddock leads to a heat stress situation during which the respiration rate and the aggressive behaviours of the cows are increased (Schütz et al., 2010). In this way, tools providing an automatic monitoring of the behaviour of dairy cows could be combined with Global Positioning System (GPS) to better detect stressful and painful situations related to grazing conditions. However, such tools should provide information about a large range of behaviours continuously and with a high accuracy to ensure a relevant detection of stressful situations. The GPS position error should also be low to provide consistent information of the position of the cows at the paddock scale. In two previous studies, a methodological framework was developed to predict a large range of behaviours of dairy cows at pasture from accelerometer data (Riaboff et al., 2019; Riaboff et al., 2020). These predicted behaviours can be combined with the position of the cows using GPS data collected on the animals. In this way, it would be possible to know where the behaviours are expressed in the pasture. In this study, we proposed to investigate whether such information could be used to relate the expressed behaviours geolocated at grazing to pasture characteristics. If the behaviour of dairy cows can be related to the main structural and botanical characteristics in the paddock, then the behaviours could be certainly used to detect stressful situations related to grazing conditions. Behaviours could also be used to detect the appropriate time to allocate a new fresh grass to the cows in a rotational grazing optimizing context. In order to carry out this proof of concept, 26 dairy cows were equipped with an accelerometer and a GPS sensor during five days of grazing in which the cows had access to two pastures alternatively. The main structural characteristics, the slope level, the soil moisture and the botanical characteristics were identified

and geolocated in each paddock. The methodology developed in the previous studies (Riaboff et al., 2019; Riaboff et al., 2020) was applied to get information about the six main behaviours of dairy cows. The Global Positioning System data were then used to get the time-budgets expressed in each zone of the pastures, per cow and per day. These time-budgets were expressed according to the pasture characteristics using a linear mixed model and an analysis of variance (ANOVA).

2. Materials and Methods

An overview of the applied methodological framework is provided in Figure 1.

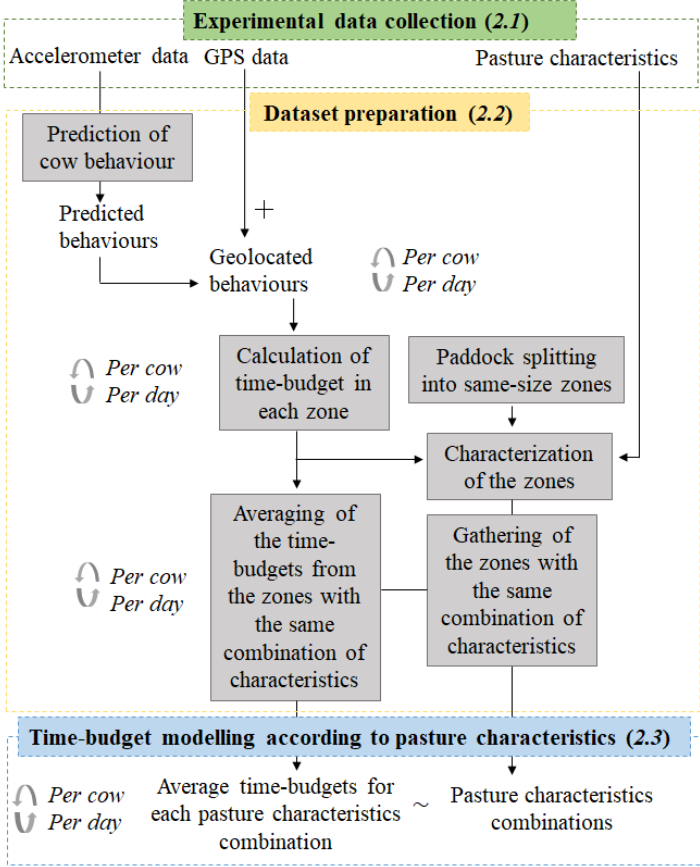


Figure 1. Overview of the main steps applied in the Material and Methods

2.1 Experimental data collection

This step aimed to collect the appropriate experimental data to investigate the effect of pasture characteristics on the behaviour of dairy cows.

2.1.1 Farm and animals description

Data collection was carried out in a 71 Holstein (milk yield: 10,000 kg per year) commercial farm in La Pommeraye, France (N 47°21'21'', O 0°51'33'') in May 2018. The average parity of the cows was 2.50 ± 1.40 (mean \pm sd) and the average days in milk was 250 ± 167 (mean \pm sd). Cows were milked using an Automatic Milking System (AMS).

Twenty-six dairy cows were chosen to be representative of the herd in terms of parity and days in milk. For the experiment, they were ranged between 16 and 253 days in milk (153.7 ± 61.0 (mean \pm sd)) with a parity ranging between one and seven (2.7 ± 1.6 (mean \pm sd)). The parity and days in milk of the herd and of the selected cows are provided in the Appendix A.

2.1.2 Collection of accelerometer and GPS data

A RF-Track datalogger (RF-Track, Rennes, France) comprising a LSM9DS1 three-axis accelerometer (STMicroelectronics, Geneva, Switzerland) $\pm 2g$ and a GPS sensor (part number EVA-7M-0, μ -Blox, Thalwil, Switzerland) with a static position error estimated at $\pm 1.72m$ was used. Data were collected at 59.5 Hz and 1 Hz for the accelerometer data and GPS data, respectively. The sensors were powered with two 3.7 V lithium batteries (2.6 Ah). Data were stored on a SD card and downloaded after the experiment. The dataloggers were 98.2 x 51.60 x 36.0 mm in size and weighed 250 g. The dataloggers were fixed on a collar and positioned on the right side of the neck. Collars were tightly adjusted and a 500 g counterweight was added to prevent them from turning around. The x-axis detected the up-down direction, the y-axis detected the backward-forward direction and the z-axis detected the left-right direction.

During the experiment, the dairy cows grazed alternatively in a first pasture of 1.6 ha (05:00 h – 11:00 h) and a second one of 2.3 ha (11:00 h – 18:00 h and 21:00 h – 05:00 h) during 5 days of grazing. The characteristics of the two pastures used during the experiment are presented in *section 2.1.3*. Cows were forced to stay in the barn from 18:00 h to 21:00 h and received a luzern forage (1.5 kg DM/cow) during this period. A grass height of 15 cm before grazing was measured in each paddock. This height grass was obtained by averaging the height grass measurements carried out every 10 m in the paddock using the GrassHopper plate meter (McSweeney et al., 2015). Based on a usual density of 250 kg DM/ha/cm, the herbage mass was 2500 kg DM/ha > 5 cm. Considering a total area of 3.9 ha for 71 dairy cows during 5 days of grazing, the herbage allowance was 27.5 kg DM/cow/day. The dairy cows received a ration of Triticale – Peas – Field beans supplementation (1.83 kg DM/cow) and Field beans (0.13 kg

DM/cow) after each AMS visit. It should be noted that the data collected from 21:00 h to 05:00 h were not used in this study.

2.1.3 Collection of pasture characteristics

Characteristics were collected in the paddocks grazed during the experiment. The first paddock (05:00 h – 11:00 h) was a permanent grassland of 1.6 ha (thereafter referred to **PG**). The second paddock (11:00 h – 18:00 h) was a temporary grassland of 2.3 ha (thereafter referred to **TG**). Locations of structural elements slope and moist soil areas are provided in the Figure 2.

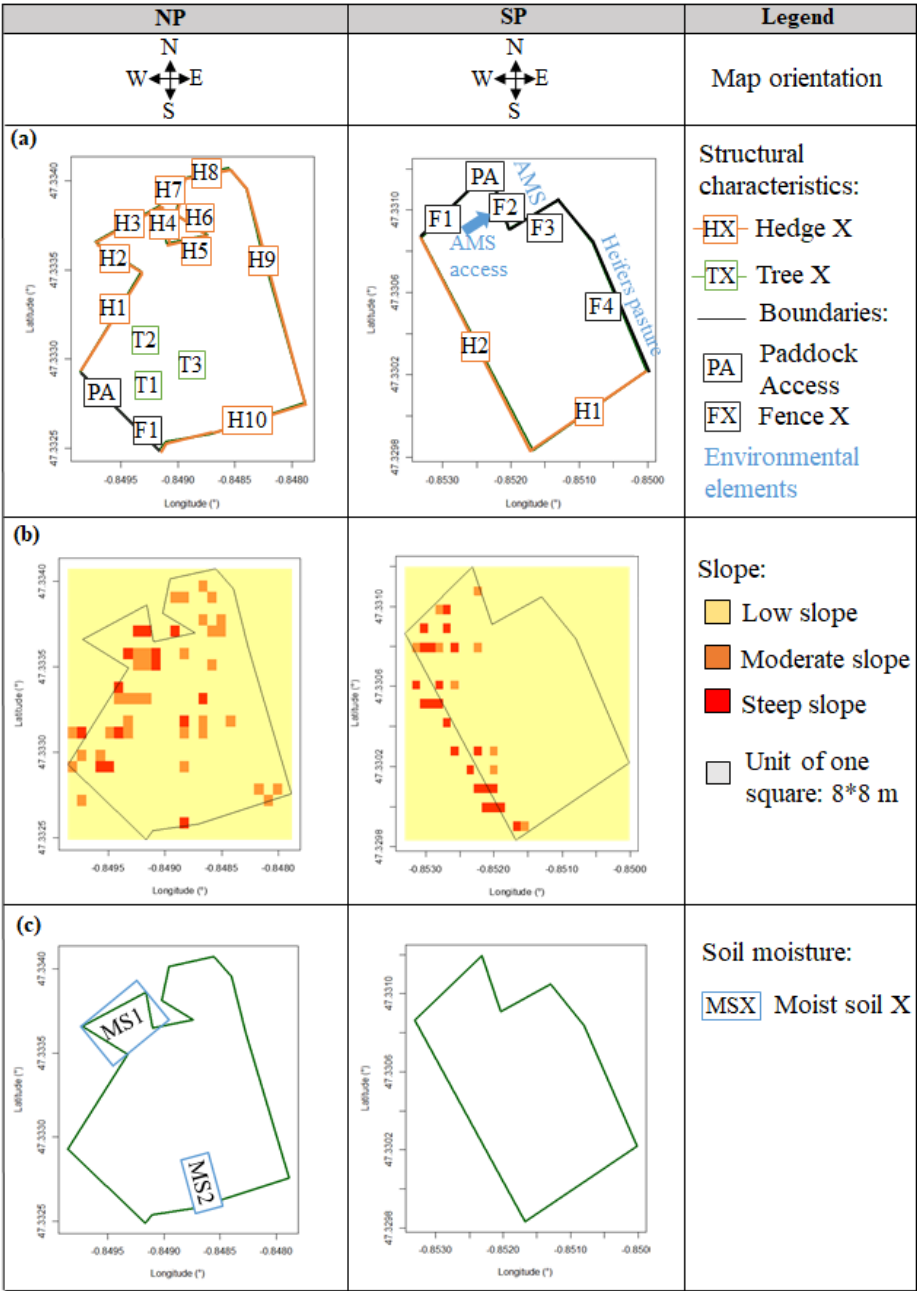


Figure 2. Description of the two paddocks grazed during the experiment based on the structural characteristics, the slope and the soil moisture.

The pasture characteristics considered in each paddock are the following:

- (i) The structural characteristics in the paddock including trees, hedges and boundaries were identified and geolocated (longitude and latitude) using the data from the French's National Geographic Institute ("Géoportail," 2006). The location of the structural elements in the paddocks is illustrated in the Figure 2(a).
- (ii) The steepest slopes were located in the paddocks using the data from the French's National Geographic Institute data ("Géoportail," 2006). Slopes ranged between 10% and 20% were referred to "moderate slope" and slopes higher than 20% were referred to "steep slope". The remaining slopes were referred to "low slope" by default. The slopes in the paddocks are shown in the Figure 2(b).
- (iii) The soil moisture was considered in the paddocks. Moist soil areas were located in the paddocks using the data from the French's National Geographic Institute ("Géoportail," 2006). Such areas were referred to "moist soil" and the remaining areas were referred to "dry soil" by default. The soil moisture in the paddocks is provided in the Figure 2(c). It should be mentioned that no moist soil area was found in TG.
- (iv) The plant species were identified using a method based on the quadrat method developed in previous studies (De Vries and de Boer, 1959; Theau et al., 2010). The measures were carried out every 10 m in the pasture using a regular grid pattern. Approximately 97 measures per hectare were carried out in each pasture, corresponding to 165 measures in PG and 182 in TG. For every measure, a rating ranged between one and 10 was attributed to the five most represented species in the area. The more a plant species was represented in the area, the more its rating was close to 10. The other plant species identified in the area were only noticed without rating. Bare ground was also considered in the rating. Seventy-six different plant species were identified in PG and 41 in TG. Each measure was also geolocated in the paddock based on the geolocation data obtained during grass height measurements with the GrassHopper plate meter (section 2.1.2).

2.2 Dataset preparation

This step aimed to get an appropriate dataset to investigate the effect of the pasture characteristics on the behaviour of dairy cows. This step was carried out for both PG and TG, separately.

2.2.1 Prediction of behaviours of dairy cows

This step aimed to get the behaviours performed successively by the 26 dairy cows over the experiment.

Two previous studies allowed predicting the main behaviours of dairy cows at pasture based on accelerometer data (Riaboff et al., 2019; Riaboff et al., 2020). The six behaviours predicted with the methodology developed in the previous studies are the following:

- Grazing: Biting or browsing taking frequent bites without raising the head
- Walking: Movement from one location to another without lowering the head at ground level.
- Ruminating while lying: Lying with regurgitating rumen bolus before it is chewing and then re-swallowing
- Ruminating while standing: Standing with regurgitating rumen bolus before it is chewing and then re-swallowing
- Resting while lying: Lying without rumination
- Resting while standing: Standing without movement or rumination

The steps carried out to develop the methodology are outlined in the Appendix B and we referred to the study of Riaboff et al. (2019) and Riaboff et al. (2020) for the complete explanation. The successive steps applied in the present study are illustrated in the Figure 3.

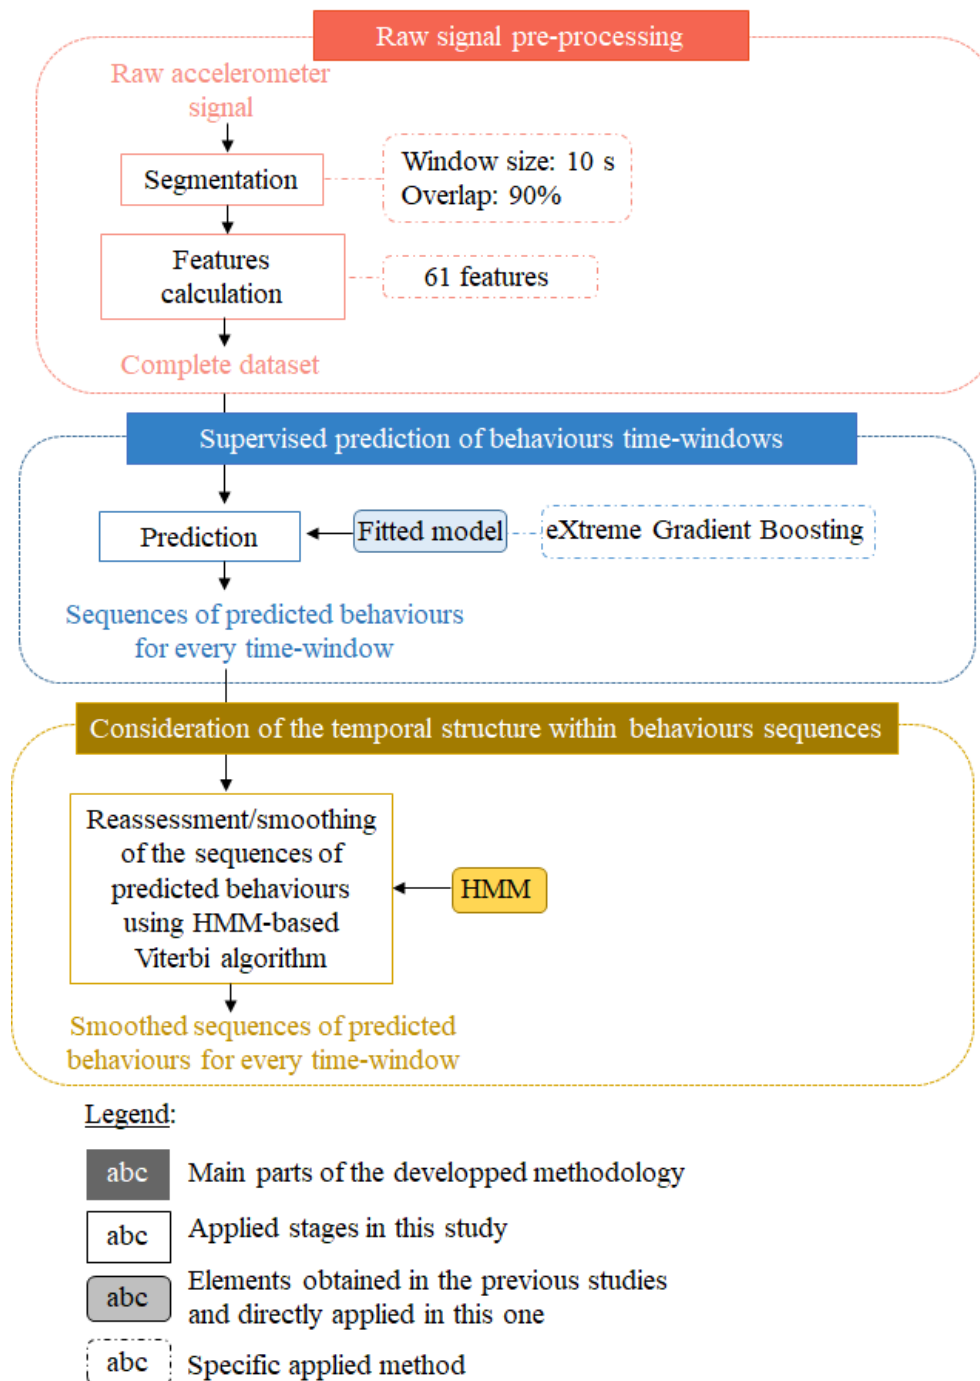


Figure 3. Description of the successive stages carried out in this study to get the predicted behaviours of dairy cows during the experiment.

At first, the raw accelerometer sequences collected on the 26 dairy cows during the 5 days of pasture were split into segments (windows) of 10 s with 90% of the data in common between two consecutive windows (overlap). This pre-processing step was performed in Matlab R2018a. The eXtreme Gradient Boosting (XGB) model fitted by Riaboff et al. (2020) was then directly used to predict the behaviours using the xgboost package (Chen et al., 2018) in R 3.6.1 software (R Core Team, 2019). At the end of this stage, the behaviour achieved throughout every

successive window of 10 s was obtained, for every cow and for every day of pasture. The predicted behaviours in the successive windows from the same cow over the entire experiment were then reassessed using the Hidden Markov Model (HMM)-based Viterbi algorithm (Forney, 1973; Witten and Frank, 2011) applied with the R package HMM (Himmelmann, 2010). The specific HMM used to apply the Viterbi algorithm in this study was those initiated by Riaboff et al. (2020).

2.2.2 Calculation of the time-budget expressed in each zone of the pastures per cow and per day

This stage aimed to (1) collect the position of the cows in the pastures while they were expressing a behaviour and (2) get the overall time and every time-budget expressed in every zone in the pastures per cow and per day.

The date and the time accurate to the second associated to each recording were collected for both accelerometer and GPS data. The time synchronisation between these two sensors was previously ensured. Each window of behaviour of 10 s was thus associated with the position (longitude and latitude) of the cow while she was expressing the behaviour, based on the date and the time of accelerometer and GPS recordings. It should be noted that the GPS data were collected every second (1 Hz), therefore there are 10-recorded positions associated to each 10 s window. The longitude and latitude selected for the 10 s-window were those corresponding to the mid-point recording within the window. The 10 s-windows of behaviour combined with the associated geographical coordinates were thereafter referred to **geolocated behaviours**.

Each paddock was split into squares of 8*8 m, thereafter referred to **zones**. This surface was chosen to broadly encompass the GPS static position error in open area (± 1.72 m) and to maintain a sufficiently fine description of the paddock. In this way, 576 zones and 841 zones were obtained after splitting in PG and TG, respectively. The geographical coordinates of each zone were recorded using the data from the French's National Geographic Institute ("Géoportail," 2006). For every cow and every day of grazing, the longitude and latitude of every geolocated behaviour was used to identify in which 8*8 m zone the cow was during the expression of the behaviour, as illustrated in the Figure 4(a).

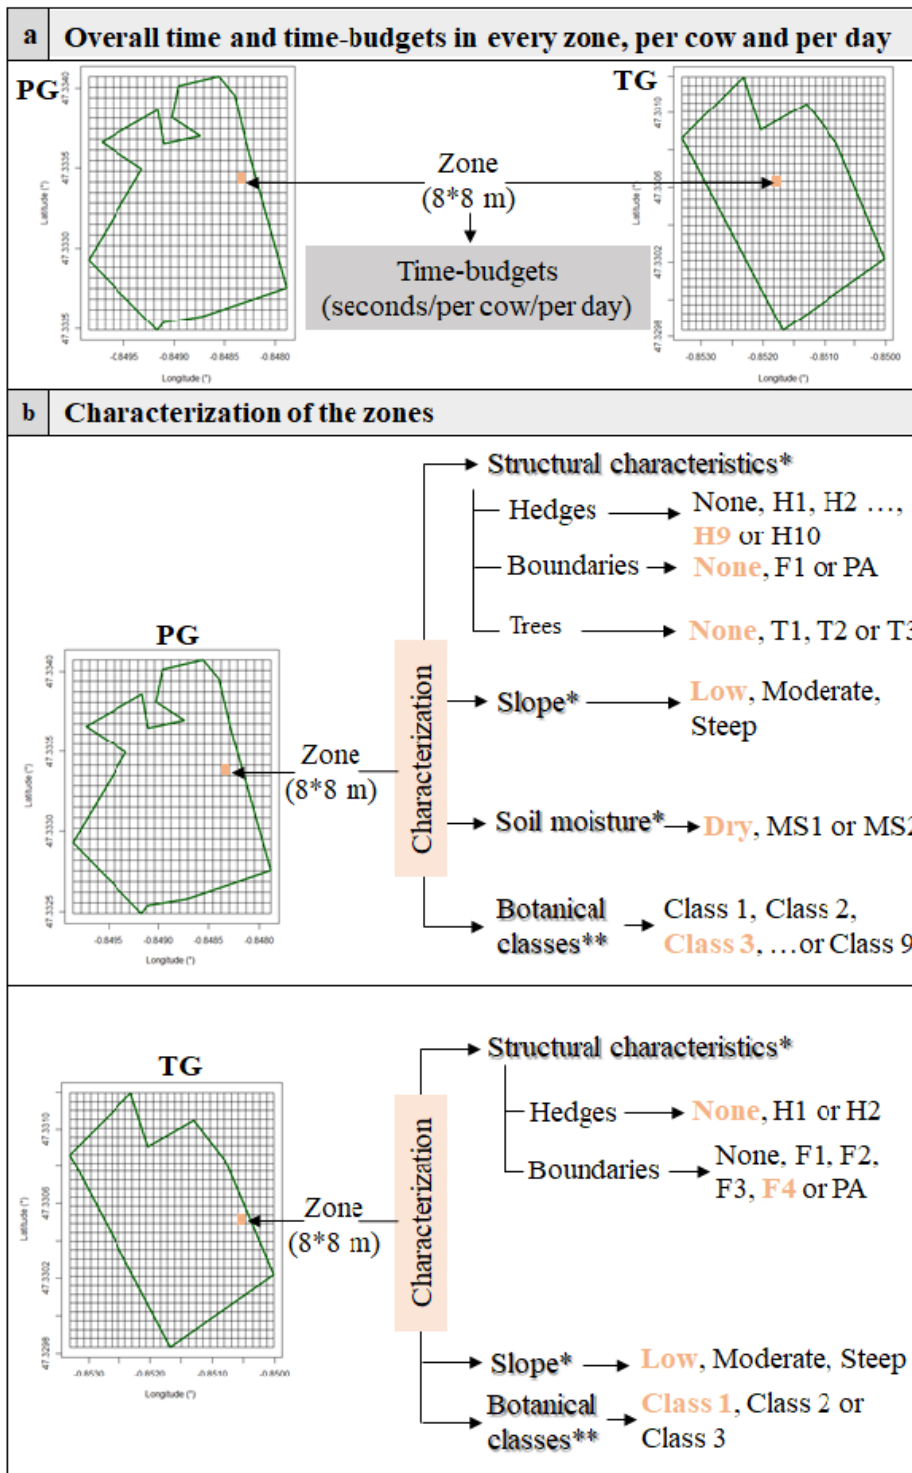


Figure 4. Overall time and time-budgets computation in every zone, per cow and per day (a) and characterization of the zones given the structural characteristics, the slope, the soil moisture and the botanical classes (b).

Note: The complete characterization of the zone in orange is those written in orange and in bold. This complete characterization constitutes a **combination** of pasture characteristics.

* referred to the description provided in the Figure 2.

** referred to the botanical classes provided in Figure 5.

This step was carried out using the R package *sp* (Gräler et al., 2016). The time-budget associated to each of the six behaviours was therefore computed in each zone of the pastures for each cow and for each day of grazing. The unit of these time-budgets (tbu) was thus seconds per surface unit of 8*8 m, per cow and per day. The overall time spent in each zone for every cow and for every day of grazing was calculated by summing the time-budgets of the corresponding zone.

2.2.3 Characterization of each zone in the paddock

This step aimed to assign the pasture characteristics to each zone in the paddocks, namely the combination of the structural characteristics, the slope, the soil moisture and the botanical characteristics, as illustrated in the Figure 4(b). The characterization of the zones was performed as follows:

- *Structural characteristics*

As explained in section 2.1.3, the structural characteristics were geolocated in the paddocks (Figure 2(a)). As the geographic coordinates of the zones were also known, zones close to structural characteristics could be identified. As illustrated in the Figure 4(b), each zone was described in terms of trees (*T1*, *T2* or *T3*), hedges (*H1... H10*) and boundaries (*F1* or *PA*) for PG and in terms of hedges (*H1* or *H2*) and boundaries (*F1*, *F2*, *F3*, *F4* or *PA*) for TG. By default, a zone was assigned to *None* if it was not located close to a structural characteristic. This step was performed using an algorithm developed in R 3.6.1 software (*R Core Team*, 2019) which involves the *sp* package (Pebesma and Bivan, 2005).

- *Slope*

As presented in section 2.1.3, the steepest slopes were located in the pastures (Figure 2(b)). The geographic coordinates of the zones were also known therefore those corresponding to a *moderate slope* or to a *steep slope* could be identified, as illustrated in the Figure 4(b). By default, the remaining zones were assigned to *low slope*. The assignment of the slope was performed with an algorithm developed in R 3.6.1 software (*R Core Team*, 2019) which involves the *sp* package (Pebesma and Bivan, 2005).

- *Soil moisture*

The areas with a moist soil were located in PG as explained in section 2.1.3 (Figure 2(c)). As illustrated in Figure 4(b), all zones geolocated in a moist soil area were assigned to *MS1* or *MS2*

depending on the position of the zone. Otherwise, the zone was characterized as *Dry*. The assignment of the soil moisture was performed using an algorithm developed in R 3.6.1 software (*R Core Team*, 2019) which involves the *sp* package (Pebesma and Bivan, 2005).

As explained in section 2.1.3, the plant species were identified in each geolocated 10*10 m area. As the number of different species identified in the paddocks was very large (76 and 41 in PG and TG, respectively), each 10*10 m geolocated area was described by a botanical class in a second stage, instead of keeping a rating for every species. For this purpose, a Hierarchical Ascendant Classification (*aggregation: Ward criterion*) was applied with the R package *FactorMiner* (Le et al., 2008) to reduce the dimension. Based on the evolution of the inertia over the aggregation process, 8 and 3 classes were identified in PG and TG, respectively. The classes were then described by the plant species which are the most represented in the class (F-test: $v\text{-test} > 2$) and by the plant species which are the least represented in the class (F-test: $v\text{-test} < -2$).

The characterization of the plant species was carried out every 10 m in the paddocks during the experimental phase (section 2.1.3). As we wanted to describe the zones in the paddock with a slightly finer scale, using a scale of 8*8 m, a spatial interpolation of the botanical classes was carried out using the R packages *gstat* (Gräler et al., 2016), *rgdal* (Bivand et al., 2019) and *raster* (Hijmans, 2019). In this way, a botanical class could be affected to each zone in PG and TG as illustrated in Figure 4(b). The description and geolocation of the botanical classes are provided in the Figure 5.

The complete characterization of a zone, involving its structural characteristics, slope, soil moisture and botanical classes constitutes a **combination** of pasture characteristics, as illustrated in Figure 4(b). Eighty-six and 23 different combinations were obtained in PG and TG, respectively.

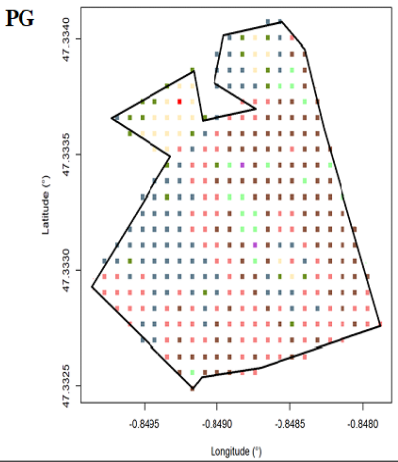








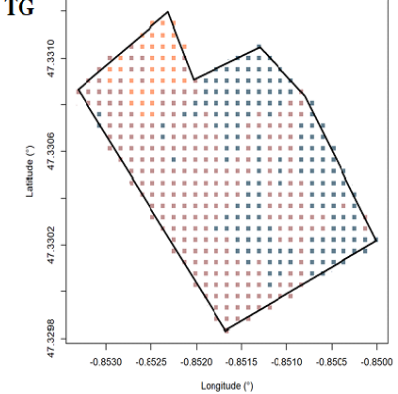



Pasture		Botanical classes			
PG 	Class	Legend	Over-represented	Under-represented	
	1		<i>Poa annual</i> ; <i>Alopecurus pratensis</i> ; <i>Silybum marianum</i>	<i>Dactylis glomerata</i>	
	2		<i>Trifolium repens</i> ; <i>Taraxacum officinale</i>	<i>Holcus lanatus</i>	
	3		<i>Holcus lanatus</i> ; <i>Cerastium</i>	<i>Festuca arundinacea</i> ; <i>Arrhenatherum elatius</i>	
	4		<i>Dactylis glomerata</i> ; <i>Vicia</i> ; <i>Rubus fruticosus</i>	<i>Holcus lanatus</i>	
	5		<i>Lolium perenne</i> ; <i>Medicago sativa</i> ; <i>Daucus carota</i>	<i>Holcus lanatus</i> ; <i>Poa annual</i> ; <i>Plantago lanceolata</i>	
	6		<i>Plantago lanceolata</i> ; <i>Trifolium pratense</i> ; <i>Achillea millefolium</i> ; Bare ground	<i>Holcus lanatus</i>	
	7		<i>Festuca arundinacea</i> ; <i>Urtica</i> ; <i>Symphytum officinale</i> ; <i>Juncus effusus</i>	<i>Lolium perenne</i>	
8		<i>Juncus effusus</i> ; <i>Anthoxanithum odoratum</i>			
TG 	1		<i>Lolium perenne</i> ; <i>Poa annual</i>	<i>Bromus hordeaceus</i> ; <i>Hordeum murinum</i>	
	2		<i>Bromus hordeaceus</i>	<i>Poa annual</i>	
	3		<i>Sisymbrium officinale</i> ; <i>Avena fatua</i>	<i>Lolium perenne</i> ; <i>Lolium perenne</i>	

Figure 5. Description and geolocation of the botanical classes in terms of over-represented and under-represented plant species for PG and TG.

2.2.4 Gathering the zones per combination and calculation of the associated average time-budgets

As explained in the previous sections, 576 and 841 zones of 8*8 m were obtained after splitting whereas only 86 and 23 different pasture characteristics combinations were identified for PG and TG, respectively. Consequently, there are many zones characterized by the same combination of pasture characteristics. To reduce this redundancy, we averaged the time-budgets of the zones with the same combination, for each cow and for each day of grazing. In this way, we obtained an average time-budget for each of the six behaviours related to each combination of pasture characteristics. The units of these time-budgets (tbu) remained seconds per surface unit 8*8 m per cow and per day.

2.3 Time-budget modelling according to pasture characteristics

This step aimed to model the overall time and time-budget of every behaviour according to the pasture characteristics, namely the structural characteristics, slope, soil moisture and botanical classes. Modelling was carried out for PG and TG, separately.

2.3.1 Consideration of the correlations between pasture characteristics

The correlations within the same type of pasture characteristics in the paddock (for instance the proximity between *H2*, *H3* and *H4*; Figure 2(a)) might skew the interpretation of the linear model. For this reason, we reduced the main correlation within the same type of pasture characteristics in the dataset before applying the linear model. A Multiple Correspondence Analysis was applied followed by a HAC (*aggregation: Ward criterion*) using the R package FactoMiner (Le et al., 2008). We identified the most correlated characteristics as those being the most represented within the same cluster (Chi square test: $v\text{-test} > 2$). We gathered the characteristics within structural elements, slopes or botanical classes which were highly correlated. A reference level was determined for each characteristic after gathering. The reference level was identified as the least specific and the most represented in the paddock. The groupings applied and the chosen reference levels for every characteristic are presented in Table 1.

Table 1. Pasture characteristics before and after the grouping carried out to reduce the correlation between characteristics for PG and TG.

		PG	
Structural characteristics	Trees	None	<i>None</i>
		T1	A1
		T2	A2
		T3	A3
	Hedges	None	<i>None</i>
		H1	H1
		H2, H3, H4	HMS1
		H5	H5
		H6	H6
		H7, H8	Hedges_North noted HN
		H9	H9
		H10	H10
	Boundaries	None	<i>None</i>
		PA	PA
		F1	F1
Slope	Low	<i>Low</i>	
	Moderate	Moderate	
	Steep	Steep	
Soil moisture	Dry	<i>Dry</i>	
	MS1	MS1	
	MS2	MS2	
Botanical classes	Class 1, Class 2	Class_slope	
	Class 3	Class 3	
	Class 4	<i>Class 4</i>	
	Class 5	Class 5	
	Class 6, 7, 8, 9	Class_Moist_Area noted Class_MA	
		TG	
Structural characteristics	Hedges	None	<i>None</i>
		H1	H1
		H2	H2
	Boundaries	None	<i>None</i>
		F1	F1
		F2, PA	Boundaries_AMS noted Bnd_AMS
		F3	F3
		F4	F4
Slope	Low	<i>Absence</i>	
	Moderate, Steep	Presence	
Botanical classes	Class 1	Class 1	
	Class 2	<i>Class 2</i>	
	Class 3	Class 3	

Note: All the notations referred to Figure 2. The gathered characteristics appear in orange; the reference level for each characteristic is those in italic.

A subsequent work was carried out to reduce the correlation between different types of pasture characteristics, as the correlation between *H2* and *MSI* (Figure 2 (a) and Figure 2 (c)). Details of the method used to reduce such correlations are provided in Appendix C. The gathering of pasture characteristics and the references levels presented in the Table 1 remained unchanged.

2.3.2 Modelling with a linear mixed model with an analysis of variance

The effect of the pasture characteristics on the overall time and time-budget was evaluated using linear mixed models. The two initial models are described with the equation (1) and (2) for PG and TG, respectively:

$$y_{ijklmnop} \sim \mu + C_i + D_j + T_k + H_l + B_m + S_n + MS_o + BC_p + e_{ijklmnop} \quad (1)$$

$$y_{ijklmn} \sim \mu + C_i + D_j + H_k + B_l + S_m + BC_n + e_{ijklmn} \quad (2)$$

where μ was the overall mean; the outcome $y_{ijklmnop}$ and y_{ijklmn} was either the overall time or the time-budgets (time spent grazing, walking, ruminating while lying, ruminating while standing, resting while lying or resting while standing) for PG and TG, respectively; C_i were the cow random effects; D_j were the fixed effect of the day of grazing; H_l and H_k were the fixed effect of hedges for PG and TG, respectively; B_m and B_l were the fixed effect of the boundaries for PG and TG, respectively; BC_p and BC_n were the fixed effect of the botanical classes for PG and TG, respectively; T_k was the fixed effect of the trees in PG; MS_o was the fixed effect of the soil moisture in PG and $e_{ijklmnop}$ and e_{ijklmn} were the random residual effects for PG and TG, respectively.

The mixed models were applied using the R package lme4 (Bates et al., 2015). A backward procedure was adopted to get the final model with only significant parameters. ANOVA of type III was carried out with the R package car (Fox and Weisberg, 2019). A Tukey test was finally applied on each explicative parameter to identify the levels which are significantly different from each other. The Tukey test was carried out with the R package emmeans (Lenth, 2019).

3. Results

3.1 Average time-budget of every behaviour for the permanent and temporary grassland

Dairy cows spent the most part to graze, representing 56.2% and 71.3% of the overall time in PG and TG, respectively. Cows also devoted a consequent part of their time to ruminate in lying position (15.9% and 12.1% in PG and TG, respectively). Rest time in lying position was about 2 times more important in PG (13.3%) than in TG (6.4%). Other behaviours were sparsely represented, leading to a percentage below 6% for both PG and TG.

3.2 Effect of each pasture characteristic on the behaviour of dairy cows

The ANOVA results associated to the definitive models and the distinguished adjusted means obtained with the Tukey test for the pasture characteristics in PG and TG are presented in Table 2 and Table 3, respectively. ANOVA results associated to the day of pasture fixed effect were reported in Appendix D. The variance and standard deviation associated to the random effects of the models were provided in Appendix E. The estimates associated to each significant effect in PG and TG are provided in Appendix F. Each effect was reported using the following order: the value of the time-budget (time-budget unit (tbu): seconds per surface unit of 8*8 m, per cow and per day); the decrease or increase factor of the time-budget associated to the effect in comparison with the basis time-budget (without any effects, *i.e.* the intercept); the significance level associated to the effect.

3.2.1 Effect of pasture characteristics on the overall time and on the behaviour of dairy cows in PG

❖ Overall time

All the effects are significant on the overall time, except the boundaries (Table 2). Cows spent more time under the trees, in particular under “T2” (97.1 tbu; + 29.39; $P < 0.001$), in the steep slope areas (12.1 tbu; + 2.78; $P < 0.01$), in the “MS2” area (15.8 tbu; + 3.9; $P < 0.05$) and in the botanical “Class_3” areas. On the contrary, cows spent less time close to “HN” (- 11.0 tbu; - 4.45; $P < 0.01$) and in “MS1” area (- 5.1 tbu; - 2.59; $P < 0.05$).

❖ Grazing time

All the effects are significant on the grazing time (Table 2). Cows spent more time to graze under trees, in particular under “T2” (35.9 tbu; + 5.99; $P < 0.001$), close to “H9” (9.4 tbu; + 0.8;

$P < 0.05$), in steep slope areas (10.9 tbu; + 1.12; $P < 0.001$), in “MS2” area (13.7 tbu; + 1.67; $P < 0.001$) and in botanical “Class_3” areas (12.0 tbu; + 1.33; $P < 0.001$). On the contrary, cows spent less time to graze near “HN” (2.4 tbu; - 1.46; $P < 0.001$) and close to “F1” (- 1.5 tbu; - 1.28; $P < 0.05$).

❖ Walking time

Only the trees and the ground affected significantly the walking behaviour ($P < 0.001$; Table 2). Cows spent more time to walk close to the trees, in particular under “T2” (3.0 tbu; + 4.55; $P < 0.001$) and close to the botanical “Class_3” areas (1.2 tbu; + 11.7; $P < 0.05$).

❖ Ruminating time

Only the trees were significant on the time spent to ruminate while lying ($P < 0.001$; Table 2). Dairy cows spent substantially more time to ruminate in lying position close to “T2” (25.8 tbu; + 236; $P < 0.001$).

Similarly, only the trees affected significantly the time spent to ruminate in standing position ($P < 0.001$; Table 2.). Dairy cows spent substantially more time to ruminate in standing position also close to “T2” (3.4 tbu; +18.15; $P < 0.001$).

❖ Resting time

Only the effect of the trees was significant on the rest time while lying ($P < 0.001$; Table 2). In particular, the dairy cows spent substantially more time to rest in lying position under “T2” (27.5 tbu; + 166.2; $P < 0.001$).

Concerning the time spent to rest in standing position, the effect was significant for the trees ($P < 0.001$; Table 2), the hedges ($P < 0.001$; Table 2) and the soil moisture ($P < 0.001$; Table 2). Cows spent more time in resting while standing under to the trees, in particular under “T2” (5.1 tbu; + 6.06; $P < 0.001$). On the contrary, cows spent less time to rest in standing position close to “HN” (- 0.59 tbu; - 1.82; $P < 0.001$) and in the “MS1” area (- 0.3 tbu; -1.41; $P < 0.001$).

Table 2. ANOVA results for PG: effect of every pasture characteristic on the overall time and on the time-budget of every behaviour.

Effect		Overall	Grazing	Walking	Ruminating - Lying	Ruminating - Standing	Resting - Lying	Resting - Standing	
Trees	Sign. ¹		***	***	***	***	***	***	
	mean \pm se	None	20.0 ^a \pm 3.7	10.6 ^a \pm 2.3	1.3 ^a \pm 0.2	1.7 ^a \pm 0.6	0.4 ^a \pm 0.2	1.1 ^a \pm 0.5	0.5 ^a \pm 0.2
		T1	40.5 ^b \pm 8.6	14.6 ^{ab} \pm 4.6	1.3 ^{ab} \pm 0.6	7.4 ^a \pm 2.6	2.8 ^{bc} \pm 0.6	6.6 ^a \pm 2.6	2.6 ^b \pm 0.6
		T2	113.9 ^c \pm 7.1	41.4 ^c \pm 4.3	3.7 ^c \pm 0.5	27.6 ^b \pm 2.1	3.6 ^c \pm 0.5	28.7 ^b \pm 2.2	4.9 ^c \pm 0.5
	T3	36.7 ^b \pm 6.2	19.1 ^b \pm 3.7	2.4 ^{bc} \pm 0.4	4.6 ^a \pm 1.7	1.9 ^b \pm 0.4	2.9 ^a \pm 1.7	1.5 ^b \pm 0.4	
Hedges	Sign. ¹		*	*	0.68	0.76	0.62	0.96	***
	mean \pm se	None	54.6 ^b \pm 4.2	22.3 ^{bc} \pm 2.7	2.2 ^a \pm 0.3	10.4 ^a \pm 1.0	2.2 ^a \pm 0.2	9.9 ^a \pm 1.0	2.7 ^b \pm 0.3
		H1	54.6 ^{ab} \pm 6.4	23.1 ^{bc} \pm 3.8	2.1 ^a \pm 0.4	10.9 ^a \pm 1.8	2.2 ^a \pm 0.4	9.4 ^a \pm 1.9	2.7 ^b \pm 0.4
		H5	56.3 ^{ab} \pm 7.7	22.6 ^{abc} \pm 4.3	2.5 ^a \pm 0.6	10.6 ^a \pm 2.3	2.1 ^a \pm 0.5	10.1 ^a \pm 2.4	2.6 ^{ab} \pm 0.5
		H6	46.2 ^{ab} \pm 6.4	18.4 ^{ab} \pm 3.7	2.0 ^a \pm 0.4	8.9 ^a \pm 1.8	1.9 ^a \pm 0.4	8.9 ^a \pm 1.8	1.8 ^{ab} \pm 0.4
		HN	40.4 ^a \pm 6.5	14.7 ^a \pm 3.8	1.7 ^a \pm 0.4	8.9 ^a \pm 1.7	1.8 ^a \pm 0.4	8.6 ^a \pm 1.7	1.4 ^a \pm 0.4
		H9	60.3 ^b \pm 6.5	26.5 ^c \pm 3.9	2.5 ^a \pm 0.5	10.3 ^a \pm 1.8	2.6 ^a \pm 0.4	10.4 ^a \pm 1.9	2.5 ^{ab} \pm 0.4
	H10	57.3 ^{ab} \pm 6.6	22.4 ^{abc} \pm 3.9	2.5 ^a \pm 0.5	12.0 ^a \pm 1.9	2.1 ^a \pm 0.4	9.9 ^a \pm 2.0	2.8 ^b \pm 0.4	
Boundaries	Sign. ¹		0.16	***	0.62	0.85	0.80	0.95	0.17
	mean \pm se	None	49.3 ^a \pm 5.4	24.6 ^b \pm 2.5	2.2 ^a \pm 0.3	10.4 ^a \pm 1.0	2.2 ^a \pm 0.2	9.9 ^a \pm 1.0	2.2 ^a \pm 0.3
		PA	43.0 ^a \pm 10.4	21.7 ^{ab} \pm 4.6	1.7 ^a \pm 0.6	9.4 ^a \pm 2.8	2.3 ^a \pm 0.6	9.6 ^a \pm 2.8	2.3 ^a \pm 0.7
	F1	37.5 ^a \pm 9.4	18.0 ^a \pm 4.1	1.9 ^a \pm 0.6	9.4 ^a \pm 2.3	1.9 ^a \pm 0.5	9.2 ^a \pm 2.4	1.4 ^a \pm 0.6	
Slope	Sign. ¹		**	***	†	0.51	0.99	0.34	0.30
	mean \pm se	Low	47.9 ^a \pm 4.7	18.6 ^a \pm 3.2	1.9 ^a \pm 0.3	10.2 ^a \pm 1.0	2.2 ^a \pm 0.2	9.6 ^a \pm 1.0	2.4 ^a \pm 0.3
		Moderate	53.6 ^{ab} \pm 5.4	21.3 ^{ab} \pm 3.5	2.1 ^a \pm 0.3	10.8 ^a \pm 1.3	2.2 ^a \pm 0.3	10.9 ^a \pm 1.3	2.7 ^a \pm 0.4
	Steep	56.8 ^b \pm 5.9	24.4 ^b \pm 3.6	2.5 ^a \pm 0.4	11.5 ^a \pm 1.5	2.2 ^a \pm 0.3	10.8 ^a \pm 1.5	2.5 ^a \pm 0.4	
Soil moisture	Sign. ¹		**	***	0.75	0.20	0.53	0.66	***
	mean \pm se	Dry	51.3 ^{ab} \pm 4.2	19.7 ^a \pm 2.9	2.2 ^a \pm 0.3	10.3 ^a \pm 1.0	2.2 ^a \pm 0.2	9.9 ^a \pm 1.0	2.6 ^a \pm 0.3
		MS1	43.1 ^a \pm 6.1	16.2 ^a \pm 3.8	2.1 ^a \pm 0.4	9.2 ^a \pm 1.4	2.0 ^a \pm 0.3	9.0 ^a \pm 1.4	1.5 ^a \pm 0.4
	MS2	63.9 ^b \pm 7.1	28.3 ^b \pm 7.1	2.5 ^a \pm 0.5	12.6 ^a \pm 2.1	2.0 ^a \pm 0.4	9.6 ^a \pm 2.1	3.0 ^a \pm 0.5	
Botanical classes	Sign. ¹		*	***	*	0.42	0.27	0.74	†
	mean \pm se	Class 4	32.6 ^a \pm 6.6	19.5 ^a \pm 3.2	2.0 ^{ab} \pm 0.3	10.2 ^a \pm 1.2	2.0 ^a \pm 0.3	9.3 ^a \pm 1.2	2.1 ^a \pm 0.3
		Class 3	42.1 ^b \pm 7.8	26.3 ^b \pm 3.7	2.7 ^b \pm 0.4	11.9 ^a \pm 1.5	2.1 ^a \pm 0.3	10.7 ^a \pm 1.5	2.0 ^a \pm 0.4
		Class 5	34.5 ^{ab} \pm 6.9	18.2 ^a \pm 3.3	1.7 ^a \pm 0.3	9.8 ^a \pm 1.2	2.5 ^a \pm 0.3	10.3 ^a \pm 1.2	2.7 ^a \pm 0.4
		Class_MA	36.7 ^{ab} \pm 7.4	21.4 ^{ab} \pm 3.5	1.9 ^{ab} \pm 0.4	9.1 ^a \pm 1.3	2.0 ^a \pm 0.3	9.1 ^a \pm 1.3	2.7 ^a \pm 0.4
	Class_slp	33.6 ^{ab} \pm 8.6	21.8 ^{ab} \pm 4.1	2.5 ^{ab} \pm 0.4	10.0 ^a \pm 1.7	2.1 ^a \pm 0.4	9.8 ^a \pm 1.7	2.4 ^a \pm 0.4	

Significant levels: *** P < 0.001; ** P < 0.01; * P < 0.05; † P < 0.1; ¹Effects of trees, hedges, boundaries, slope, soil moisture and botanical classes; ^{a-c} distinguish adjusted means that are different for trees, hedges, boundaries, slope, soil moisture and botanical classes (P < 0.05, Tukey's pairwise comparison). All the notations referred to Table 1.

3.2.2 Effect of pasture characteristics on the overall time and on the behaviour of dairy cows in TG

❖ Overall time

All the effects are significant on the overall time, except the slope (Table 3). Cows spent more time close to “F4” (19.5 tbu; + 0.6; $P < 0.1$) and in botanical “Class_3” areas (18.6 tbu; + 0.58; $P < 0.05$). On the contrary, they spent less time near “H2” (1.0 tbu; - 0.9; $P < 0.001$) and close to “F1” (6.4 tbu; - 0.45; $P < 0.1$).

❖ Grazing time

A significant effect on the grazing time was found for the hedges ($P < 0.05$; Table 3) and the botanical classes ($P < 0.05$; Table 3). Cows spent less time to graze in areas close to “H2” (0.6 tbu; - 0.91; $P < 0.001$) and more time in botanical “Class_3” areas (11.7 tbu; + 0.51; $P < 0.05$).

❖ Walking time

The behaviour “Walking” was significantly affected by the botanical classes exclusively ($P < 0.05$; Table 3). As for the grazing behaviour, they spent more time to walk in botanical “Class_3” (0.93 tbu; + 1.06; $P < 0.01$).

❖ Ruminating time

Only the botanical classes affected significantly the time spent to ruminate in lying position ($P < 0.05$; Table 3) with more rumination while lying in botanical “Class_3” areas (1.63 tbu; + 10.2; $P < 0.01$).

The time spent in ruminating in the standing position was significantly impacted by the boundaries exclusively ($P < 0.001$; Table 3.). Dairy cows spent more time to ruminate while standing close to “F4” (1.70 tbu; + 5.24; $P < 0.001$).

❖ Resting time

No pasture characteristic affected the time spent to rest while lying (Table 3). The time spent to rest while standing was significantly affected by the boundaries ($P < 0.01$; Table 3). Dairy cows spent more time to rest while standing close to “F4” (2.2 tbu; + 3.10; $P < 0.001$).

Table 3. ANOVA results for TG: effect of every pasture characteristic on the overall time and on the time-budget of every behaviour.

Effect		Overall	Grazing	Walking	Ruminating - Lying	Ruminating - Standing	Resting - Lying	Resting - Standing	
Hedges	Sign. ¹	*	*	0.27	0.37	0.39	0.31	0.22	
	mean \pm se	None	16.8 ^b \pm 2.2	11.6 ^b \pm 1.4	0.6 ^a \pm 0.1	1.9 ^a \pm 0.4	0.7 ^a \pm 0.2	0.8 ^a \pm 0.2	0.9 ^a \pm 0.2
		H1	14.3 ^{ab} \pm 3.9	11.4 ^{ab} \pm 2.2	0.5 ^a \pm 0.2	1.3 ^a \pm 0.7	0.8 ^a \pm 0.4	0.4 ^a \pm 0.3	0.3 ^a \pm 0.4
		H2	6.1 ^a \pm 4.7	4.5 ^a \pm 2.7	0.1 ^a \pm 0.3	0.7 ^a \pm 0.9	0.2 ^a \pm 0.4	0.8 ^a \pm 0.2	0.4 ^a \pm 0.5
Boundaries	Sign. ¹	*	0.23	0.46	0.22	**	0.24	**	
	mean \pm se	None	12.8 ^{ab} \pm 2.1	9.4 ^a \pm 1.5	0.5 ^a \pm 0.1	1.9 ^a \pm 0.4	0.5 ^a \pm 0.2	0.7 ^a \pm 0.2	0.5 ^a \pm 0.2
		F1	7.5 ^a \pm 3.4	7.1 ^a \pm 2.5	0.4 ^a \pm 0.2	0.7 ^a \pm 0.6	0.3 ^a \pm 0.3	0.4 ^a \pm 0.3	0.5 ^a \pm 0.3
		Bnd_AMS	9.9 ^{ab} \pm 3.9	7.1 ^a \pm 2.9	0.7 ^a \pm 0.2	2.1 ^a \pm 0.7	0.4 ^a \pm 0.3	0.8 ^a \pm 0.3	0.7 ^a \pm 0.3
		F3	11.3 ^{ab} \pm 5.6	10.1 ^a \pm 4.1	0.5 ^a \pm 0.4	1.1 ^a \pm 1.2	0.6 ^{ab} \pm 0.5	0.4 ^a \pm 0.6	0.5 ^{ab} \pm 0.6
		F4	20.6 ^b \pm 4.6	13.1 ^a \pm 3.3	0.9 ^a \pm 0.3	2.8 ^a \pm 0.9	1.9 ^b \pm 0.4	1.5 ^a \pm 0.4	2.2 ^b \pm 0.4
Slope	Sign. ¹	0.96	0.77	0.90	0.94	0.86	0.64	0.62	
	mean \pm se	Absence	12.5 ^a \pm 3.0	9.0 ^a \pm 1.6	0.5 ^a \pm 0.1	1.7 ^a \pm 0.4	0.7 ^a \pm 0.3	0.8 ^a \pm 0.2	2.4 ^a \pm 0.3
		Presence	12.6 ^a \pm 4.5	9.5 ^a \pm 2.0	0.5 ^a \pm 0.2	1.7 ^a \pm 0.5	0.7 ^a \pm 0.2	0.7 ^a \pm 0.2	2.7 ^a \pm 0.4
Botanical classes	Sign. ¹	*	*	*	*	0.45	0.57	0.22	
	mean \pm se	Class 2	11.7 ^a \pm 2.4	9.1 ^{ab} \pm 1.4	0.4 ^{ab} \pm 0.1	1.2 ^a \pm 0.3	0.7 ^a \pm 0.1	0.8 ^a \pm 0.2	0.8 ^a \pm 0.2
		Class 1	6.9 ^a \pm 4.4	5.2 ^a \pm 2.7	0.2 ^a \pm 0.3	1.2 ^a \pm 0.8	0.9 ^a \pm 0.4	0.4 ^a \pm 0.4	0.7 ^a \pm 0.5
		Class 3	18.6 ^b \pm 3.9	13.1 ^b \pm 2.1	0.9 ^b \pm 0.2	2.7 ^a \pm 0.5	1.0 ^a \pm 0.3	0.7 ^a \pm 0.3	1.3 ^a \pm 0.3

Significant levels: *** P < 0.001; ** P < 0.01; * P < 0.05; † P < 0.1; ¹Effects of hedges, boundaries, slope and botanical classes;

^{a - c} distinguish adjusted means that are different for hedges, boundaries, slope and botanical classes (P < 0.05, Tukey's pairwise comparison). The means are expressed in seconds per surface unit of 8*8 m, per cow and per day. All the notations referred to Table 1.

4. Discussion

4.1 Organization of the cows in the two used pastures

4.1.1 Different organization of the behaviour of dairy cows depending on the grassland

The two paddocks grazed during the experiment were very different in terms of pasture characteristics. The PG involved many natural structural elements, moist areas and a large diversity of plant species dispersed in the field. Conversely, the TG was limited to two hedges and was essentially composed by some major plant species, including ray-grass, bluegrass and brome. However, the TG was opened directly to the AMS and to heifers, which were additional components likely to influence behaviour of cattle. The results of the study showed that these disparities in the structure and the composition of the paddocks led to a different organization of the behaviours of dairy cows. A strong organization was observed in the PG around the main pasture characteristics, reflected by some preferred areas or in contrast rejected areas. Dairy cows spent more time under trees, whatever the achieved behaviour. They spent more time to graze in the “MS2” area and in the botanical “Class_3” areas, which are mainly constituted by *Holcus lanatus* and *Cerastium* species (Figure 5). In contrast, the “MS1” area was under-visited by the cows. Their behaviour seems therefore very structured around the pasture characteristics in a diversified pasture context. Conversely, the organization of dairy cows in the TG was less pronounced. Cows spent more time in the botanical “Class_3” areas (*Sisymbrium officinale* and *Avena fatua* (Figure 5)) which were in the AMS access and close to the fence “F4” which directly opened to heifers. Therefore, their behaviour appears to be more influenced by the external environment than by the pasture characteristics themselves in a few contrasted pasture context.

4.1.2 Consistency between the organization found with accelerometer and GPS sensors and the literature

The relations found between the behaviours of the cows and the pasture characteristics seem broadly consistent with the literature in both PG and TG. In PG, the attractiveness for the trees was in accordance with Schütz et al. (2010) where a highly motivation of the cows to use shade was reported in warm weather conditions. It should be noted that a temperature between 8°C and 15°C was recorded during our experiment, except for the last day where the temperature reached 21°C in the afternoon (Météo France, 2019). However, the weather was sunny during the whole experiment so the dairy cows may seek shade from the trees to protect themselves

against the sun, in particular to rest and ruminate. It should be noted that the favoured tree “T2” was the most massive tree, providing a large coverage of shade. This result was in agreement with the study of Schütz et al. (2010) in which cows spent more time in the larger shade. In the study of Schütz et al. (2010), the main behaviour achieved in shaded areas was standing and the behaviour lying was more applied in shaded areas than in other places, which is also in accordance with our results. The time spent to graze was more important in areas close to trees, as already reported in literature (Batista et al., 2019; Rook et al., 2004). Dairy cows spent more time to graze in the “MS2” area, which was located near a natural source of water. As there was no drinking trough in the paddock, cows may spend more time to graze in “WG2” because of the proximity of the water source, as observed by Batista et al. (2019). Cows also spent more time to graze in botanical “Class_3” areas, which were mainly constituted by *Holcus lanatus* and *Cerastium* species. This finding corroborates those of O’Donnell and Walton (1969) in which free-ranging cattle in an Irish hill-farm spent 81% of their time to graze spots with *Holcus lanatus*. This comparison should however be nuanced as the other botanical species in the pasture were different from those of our study. In contrast, the botanical “Class_5” characterized by a high proportion of *Lolium perenne* was significantly less grazed by the cows which seems surprising in view of the literature (Rutter et al., 2004). However, it should be stated that areas with *Lolium perenne* were more dispersed in the paddock than *Holcus lanatus* areas which were concentrated close to “H9” (Figure 5.). As stated by Rook et al. (2004), the ruminants usually seek a compromise between the benefits of eating a preferred food and the costs of foraging for that food, explaining potentially why the *Lolium perenne* areas were less grazed in our study. Furthermore, Rutter et al. (2004) showed that dairy cows eat preferentially a mixed diet. As *Lolium perenne* was very abundant in the temporary grassland, it is possible that the cows grazed other species preferentially in PG. Finally, it should be mentioned that *Lolium perenne* was not an over-represented species of the botanical “Class_3” but it still represented 23% of the species of this botanical class (*data not shown*).

In TG, cows spent more time in the botanical “Class_3” areas which is surprising as the corresponding vegetation (*Sisymbrium officinale* and *Avena fatua*) is *a priori* no palatable. This effect is maybe skewed as this class of botanical class was largely under-represented in the paddock compared to the two other botanical classes. It leads to an unbalanced dataset which is not suitable for an analysis of variance and requires to qualify this effect. Furthermore, even if no effect was found for the boundaries close to AMS (“Bnd_AMS”), the “Class_3” areas were located in the path access of the AMS. Cows may spend more time in these areas because of the regular travels from the paddock to the AMS and conversely. This hypothesis also

contributes to explain why more displacement was achieved in these areas. Dairy cows spent more time to stand close to the fence “F4” which directly opened to heifers. This result seems consistent as cows are gregarious animals (Arave and Albright, 1981). The hedges constituted the only shaded areas in the sown paddock but they were not used by the dairy cows contrary to what we expected (Schütz et al., 2010). However, Schütz et al. (2010) mentioned that shade areas are mainly used for the resting behaviour, both in standing and lying posture. Therefore, the under-use of the hedges in the sown pasture should be nuanced as the resting behaviours were under-represented in TG (10.1% of the overall time corresponding to only 19.8 minutes of resting in average per cow and per day). Moreover, the results obtained during the night on the same paddock highlight a substantial use of the hedges for the resting behaviours (*data not shown*). Finally, the botanical composition of hedges was not explored so we cannot explain why the cows do not apparently used hedges as a food resource.

The methodology developed in our previous studies (Riaboff et al., 2019; Riaboff et al. 2020) followed by a combination with GPS data could highlight the most significant pasture characteristics in accordance with the literature. In this way, it can certainly be used to reverse the problem, *i.e.*, use the predicted behaviours to detect an abnormal situation related to grazing conditions, in an animal welfare or pasture optimization context, as explained in the following sections.

4.2 Practical implications of the used methodology

4.2.1 Monitoring of animal health and welfare

❖ Animal welfare monitoring

Considering animal welfare currently generates interest in view of the benefits for animals, farmers and consumers (Dawkins, 2017). As an adaptation of the animals in relation to an internal or external challenge is initially expressed by a change of behaviour (Wechsler, 1995), our methodology could be used to detect a specific stress situation. Based on this approach, O’Driscoll et al. (2019) tried to highlight undernutrition at pasture, which is one the Five Freedoms (“Farm Animal Welfare Committee (FAWC),” 2011). For this purpose, they investigated the effect of the feed allowance at pasture on the lying duration and on the number of lying bouts recorded with pedometers. Similarly, our methodology could be used to identify the evolution of the entire range of behaviours of dairy cows, in connection with their position in relation to grazing conditions. This would enable to explore the change based on a complete description of behaviours in order to identify specific patterns related to undernutrition in

pasture. Furthermore, the present study confirmed that cows used shaded areas to protect themselves against solar radiation or high temperature. In absence of shaded areas, an aggressive (Schütz et al., 2010) or a congregating behaviour close to drinking trough (Riaboff et al., 2018; Widowski, 2001) is expected. Such abnormal behaviours related to heat stress could be easily detected with the methodology used in this study in order to ensure animal welfare at grazing.

❖ Animal health monitoring : the particular case of lameness detection

Lameness is associated to changes to the behaviours of dairy cows (Chapinal et al., 2009), suggesting that behaviours could be used to detect lame cows (Barker et al., 2018). As mentioned by Willshire and Bell (2009), information about lying and feeding behaviour should help to improve both sensitivity and specificity of lameness detection, which are currently low (Rutten et al., 2013). Consequently, the methodological framework developed in our study may be relevant to the development of sensors predicting cow behaviour for the detection of lameness. Such a tool would allow earlier treatments and mitigate the pain and costs associated with the disease (Willshire and Bell, 2009).

4.2.2 Optimization of pasture management in a rotational grazing system

As explained by Fulkerson et al. (2005), the allocation of sufficient fresh grass at pasture in a rotational grazing system can result in ~ 10% higher milk yield. Currently, the estimation of the available grass at pasture is based on grass height measurements which are laborious and time-consuming (French et al., 2015). For this reason, a tool ensuring a simple detection of an insufficient pasture biomass could be a useful way to achieve a maximum utilization of grazed grass in a rotational grazing system (French et al., 2015). It seems that an insufficient grass allocation leads to change in both feeding behaviours (Werner et al., 2019) and lying behaviour (O'Connor et al., 2019). Other studies suggest that insufficient grass allocation leads to an increase of the distance travelled by the cows (Manning et al., 2017). Besides, a daily and a half-day evolution of behaviours was observed in our study and in a previous one (Riaboff et al., 2018), respectively. The grass resource has never been insufficient in our study to observe a change of behaviour associated to the decrease of grass allocation but our methodology could be used to explore this change using an adapted experimental design. In this way, the behaviour of dairy cows could be used to predict the appropriate time to provide allocation of fresh grass.

Finally, our methodology could also be used to adjust the amount of supplement distributed to each cow, especially when an AMS is used. Thus, the grazing time derived from the methodology could be related to the dairy production of each cow measured by the AMS in order to adapt the amount of concentrate distributed.

4.3 Towards an integrative tool for farming management

So far, few tools are available to improve the management of pasture-based systems and added value of the existing tools is not really perceived by farmers (French et al., 2015). Based on the literature and on the present study, our methodology could be used to develop an integrative tool for pasture management, including the detection of breeding events (Shahriar et al., 2016), the monitoring of welfare (Rushen et al., 2012) and health, especially lameness (Barker et al., 2018). Our methodology should also be used to make recommendations for farmers to help them in their decision (Werner et al., 2019). However, several steps are still needed to design such a tool. First, our methodology still has some limitations for implementation in farming. Thus, the genericity of the algorithms and the prediction of some behaviours should be improved (Riaboff et al., 2020). Furthermore, the development of other algorithms to detect each event based on the predicted behaviours is required. The instrumentation of the sensor also needs to be considered. The high sampling frequency of the GPS and accelerometer (1 Hz and 59.5 Hz, respectively) should be certainly decreased (Benaissa et al., 2017) to (1) ensure an automatic transfer of the data and to (2) increase the battery life. A substantial work of instrumentation is therefore required before we can consider the methodology applicable for the previously proposed implications.

5. Conclusion

A methodology allowing the prediction of the main behaviours of dairy cows at grazing based on accelerometer data was developed in previous studies. The predicted behaviours can then be combined with GPS data to know where the behaviours are expressed in pasture. This study aimed to relate the behaviours of dairy cows at grazing to the main pasture characteristics using the methodology and the subsequent combination with GPS data. Even if this experiment deserves to be carried out again in different conditions before concluding on the specific use of pasture characteristics in the pastures, this study shows that (1) the behaviours of dairy cows can be related to the main pasture characteristics in agreement with the literature and (2) the predicted behaviours combined with the position of the cows should be used to infer stressful situation (heat stress, undernutrition...) associated to grazing conditions. This methodology

could thus be used to monitor animal welfare at grazing. Finally, the methodology developed combined with GPS data could also be implemented in an integrative tool for pasture-based systems, including the detection of oestrus, monitoring the health and welfare of dairy cows and making recommendations to farmers to help them in their decision-making.

Acknowledgments

We thank the commercial farm GAEC Haute-Roue (La Pommeraye, Nantes) where the experiment took place. We also thank Marie Roig-Pons and Jacques Magnier for their assistance in data collection.

Funding source

This study was funded by Terrena Innovation and the region of Pays-de-la-Loire (France).

References

- Arave, C.W., Albright, J.L., 1981. Cattle behaviour. *J. Dairy Sci.* 64, 1318–1329.
- Bates, D., Maechler, M., Bolker, B., Walker, S., 2015. Fitting Linear Mixed-Effects Models Using lme4. *J. Stat. Softw.* 67, 1–48. <https://doi.org/10.18637/jss.v067.i01>
- Batista, P.H.D., Almeida, G.L.P.D., Sarmento, R.M., Pandorfi, H., Melo, A.A.S.D., Rolim, M.M., Medeiros, V.W.C.D., Gonçalves, G.E., 2019. Monitoring the bovine activity in grazing by an electronic sensing device based on GPS. *Rev. Ciênc. Agrár.* vol. 42 n.º 2 (2019)-. <https://doi.org/10.19084/rca.17264>
- Barker, Z.E., Vázquez Diosdado, J.A., Codling, E.A., Bell, N.J., Hodges, H.R., Croft, D.P., Amory, J.R., 2018. Use of novel sensors combining local positioning and acceleration to measure feeding behavior differences associated with lameness in dairy cattle. *J. Dairy Sci.* 101, 6310–6321. <https://doi.org/10.3168/jds.2016-12172>
- Benaissa, S., Tuytens, F.A.M., Plets, D., de Pessemier, T., Trogh, J., Tanghe, E., Martens, L., Vandaele, L., Van Nuffel, A., Joseph, W., Sonck, B., 2017. On the use of on-cow accelerometers for the classification of behaviours in dairy barns. *Res. Vet. Sci.* <https://doi.org/10.1016/j.rvsc.2017.10.005>
- Bivand, R., Keitt, T., Rowlingson, B., 2019. rgdal: Bindings for the “Geospatial” Data Abstraction Library.
- Cardoso, C.S., Hötzel, M.J., Weary, D.M., Robbins, J.A., von Keyserlingk, M.A.G., 2016. Imagining the ideal dairy farm. *J. Dairy Sci.* 99, 1663–1671. <https://doi.org/10.3168/jds.2015-9925>
- Chapinal, N., Passillé, A.M. de, Weary D. M., von Keyserlingk A. G., Rushen J., 2009. Using gait score, walking speed, and lying behavior to detect hoof lesions in dairy cows. *J. Dairy Sci.* <https://doi.org/10.3168/jds.2009-2115>
- Chen, T., He, T., Benesty, M., Khotilovich, V., Tang, Y., Cho, H., Chen, K., Mitchell, R., Cano, I., Zhou, T., Li, M., Xie, J., Lin, M., Geng, Y., Li, Y., 2018. xgboost: Extreme Gradient Boosting.
- Dawkins, M.S., 2017. Animal welfare and efficient farming: is conflict inevitable? *Anim. Prod. Sci.* 57, 201. <https://doi.org/10.1071/AN15383>
- De Vries, D.M. (viaf)290898456, de Boer, Th.A., 1959. Methods used in botanical grassland research in the Netherlands and their application. Publ. 1959 Wagening. Inst. Voor Biol. En Scheikd. Onderz. Van Landbouwgewassen.
- Farm Animal Welfare Committee (FAWC) [WWW Document], 2011. URL <https://www.gov.uk/government/groups/farm-animal-welfare-committee-fawc>
- Forney, G.D., 1973. The Viterbi Algorithm. *Proc. IEEE* 61, 268–278.
- Fox, J., Weisberg, S., 2019. An {R} Companion to Applied Regression. Sage, Thousand Oaks CA.
- French, P., O’Brien, B., Shalloo, L., 2015. Development and adoption of new technologies to increase the efficiency and sustainability of pasture-based systems. *Anim. Prod. Sci.* 55, 931. <https://doi.org/10.1071/AN14896>
- Fulkerson, W.J., McKean, K., Nandra, K.S., Barchia, I.M., 2005. Benefits of accurately allocating feed on a daily basis to dairy cows grazing pasture. *Aust. J. Exp. Agric.* 45, 331. <https://doi.org/10.1071/EA03109>
- Géoportail [WWW Document], 2006. Portail Natl. Connaiss. Territ. Mis En Oeuvre Par IGN. URL <https://www.geoportail.gouv.fr/>
- Gräler, B., Pebesma, E., Heuvelink, G., 2016. Spatio-Temporal Interpolation using gstat. *R J.* 8, 204–218.
- Hijmans, R.J., 2019. raster: Geographic Data Analysis and Modeling.
- Himmelman, L., 2010. HMM: HMM - Hidden Markov Models.

- Hofstetter, P., Frey, H.-J., Gazzarin, C., Wyss, U., Kunz, P., 2014. Dairy farming: indoor v. pasture-based feeding. *J. Agric. Sci.* 152, 994–1011. <https://doi.org/10.1017/S0021859614000227>
- Le, S., Fosse, J., Husson, F., 2008. FactoMineR: An R Package for Multivariate Analysis. *J. Stat. Softw.* 25, 1–18. <https://doi.org/10.18637/jss.v025.i01>
- Lenth, R., 2019. emmeans: Estimated Marginal Means, aka Least-Squares Means.
- Manning, J., Cronin, G., González, L., Hall, E., Merchant, A., Ingram, L., 2017. The Behavioural Responses of Beef Cattle (*Bos taurus*) to Declining Pasture Availability and the Use of GNSS Technology to Determine Grazing Preference. *Agriculture* 7, 45. <https://doi.org/10.3390/agriculture7050045>
- McSweeney, D., Foley, C., Halton, P., O'Brien, B., 2015. Calibration of an automated grass measurement tool to enhance the precision of grass measurement in pasture based farming systems. Presented at the Teagasc Ag conference, Tullamore.
- Météo France, 2019. Météo France - données publiques [WWW Document]. URL <https://donneespubliques.meteofrance.fr/>
- O'Brien, D., Shalloo, L., Patton, J., Buckley, F., Grainger, C., Wallace, M., 2012. A life cycle assessment of seasonal grass-based and confinement dairy farms. *Agric. Syst.* 107, 33–46. <https://doi.org/10.1016/j.agry.2011.11.004>
- O'Connor, A.H., Bokkers, E.A.M., de Boer, I.J.M., Hogeveen, H., Sayers, R., Byrne, N., Ruelle, E., Shalloo, L., 2019. Associating cow characteristics with mobility scores in pasture-based dairy cows. *J. Dairy Sci.* 102, 8332–8342. <https://doi.org/10.3168/jds.2018-15719>
- O'Donnell, T.G., Walton, G.A., 1969. SOME OBSERVATIONS ON THE BEHAVIOUR AND HILL-PASTURE UTILIZATION OF IRISH CATTLE. *Grass Forage Sci.* 24, 128–133. <https://doi.org/10.1111/j.1365-2494.1969.tb01057.x>
- O'Driscoll, K., Lewis, E., Kennedy, E., 2019. Effect of feed allowance at pasture on the lying behaviour of dairy cows. *Appl. Anim. Behav. Sci.* 213, 40–46. <https://doi.org/10.1016/j.applanim.2019.02.002>
- Pebesma, E.J., Bivan, R.S., 2005. Classes and methods for spatial data in R.
- Phillips, C.J.C., Rind, M.I., 2002. The Effects of Social Dominance on the Production and Behavior of Grazing Dairy Cows Offered Forage Supplements. *J. Dairy Sci.* 85, 51–59. [https://doi.org/10.3168/jds.S0022-0302\(02\)74052-6](https://doi.org/10.3168/jds.S0022-0302(02)74052-6)
- R Core Team, 2019. , R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria.
- Ranjbar, S., Rabiee, A.R., Gunn, A., House, J.K., 2016. Identifying risk factors associated with lameness in pasture-based dairy herds. *J. Dairy Sci.* 99, 7495–7505. <https://doi.org/10.3168/jds.2016-11142>
- Riaboff, L., Aubin, S., Bédère, N., Couvreur, S., Madouasse, A., Goumand, E., Chauvin, A., Plantier, G., 2019. Evaluation of pre-processing methods for the prediction of cattle behaviour from accelerometer data. *Comput. Electron. Agric.* 165, 104961. <https://doi.org/10.1016/j.compag.2019.104961>
- Riaboff, L., Poggi, S., Madouasse, A., Couvreur, S., Aubin, S., Bédère, N., Goumand, E., Chauvin, A., Plantier, G., 2020. Development of a methodological framework for a robust prediction of the main behaviours of dairy cows using a combination of machine learning algorithms on accelerometer data. *Comput. Electron. Agric.* 169, 105179. <https://doi.org/10.1016/j.compag.2019.105179>
- Riaboff, L., Bedere, N., Couvreur, S., Aubin, S., Goumand, E., Magnier, J., Madouasse, A., Chauvin, A., Plantier, G., 2018. Influence of pasture characteristics and time of day on dairy cow behaviour predicted from GPS-data. *7 Gen. Meet. Eur. Grassl. Fed. EGF* 23, 803–809.

- Rook, A.J., Harvey, A., Parsons, A.J., Orr, R.J., Rutter, S.M., 2004. Bite dimensions and grazing movements by sheep and cattle grazing homogeneous perennial ryegrass swards. *Appl. Anim. Behav. Sci.* 88, 227–242. <https://doi.org/10.1016/j.applanim.2004.03.006>
- Rushen, J., Chapinal, N., de Passillé, A., 2012. Automated monitoring of behavioural-based animal welfare indicators. *Anim. Welf.* 21, 339–350. <https://doi.org/10.7120/09627286.21.3.339>
- Rutten, C.J., Velthuis, A.G.J., Steeneveld, W., Hogeveen, H., 2013. Sensors to support health management on dairy farms. *J. Dairy Sci.* 1928–1952.
- Rutter, S.M., Orr, R.J., Yarrow, N.H., Champion, R.A., 2004. Dietary Preference of Dairy Cows Grazing Ryegrass and White Clover. *J. Dairy Sci.* 87, 1317–1324. [https://doi.org/10.3168/jds.S0022-0302\(04\)73281-6](https://doi.org/10.3168/jds.S0022-0302(04)73281-6)
- Schütz, K.E., Rogers, A.R., Poulouin, Y.A., Cox, N.R., Tucker, C.B., 2010. The amount of shade influences the behavior and physiology of dairy cattle 93, 9.
- Shahriar, Md.S., Smith, D., Rahman, A., Freeman, M., Hills, J., Rawnsley, R., Henry, D., Bishop-Hurley, G., 2016. Detecting heat events in dairy cows using accelerometers and unsupervised learning. *Comput. Electron. Agric.* 128, 20–26. <https://doi.org/10.1016/j.compag.2016.08.009>
- Theau, J.P., Cruz, P., Fallour, D., Jouany, E., Lecloux, E., Duru, M., 2010. Une méthode simplifiée de relevé botanique pour une caractérisation agronomique des prairies permanentes. *Fourrages* 201, 19–25.
- Vermunt, J.J., Greenough, P.R., 1995. Structural characteristics of the bovine claw: Horn growth and wear, horn hardness and claw conformation. *Br. Vet. J.* 151, 157–180. [https://doi.org/10.1016/S0007-1935\(95\)80007-7](https://doi.org/10.1016/S0007-1935(95)80007-7)
- Wechsler, B., 1995. Coping and coping strategies: a behavioural view. *Appl. Anim. Behav. Sci.* 43, 123–134. [https://doi.org/10.1016/0168-1591\(95\)00557-9](https://doi.org/10.1016/0168-1591(95)00557-9)
- Werner, J., Umstatter, C., Kennedy, E., Grant, J., Leso, L., Geoghegan, A., Shalloo, L., Schick, M., O'Brien, B., 2019. Identification of possible cow grazing behaviour indicators for restricted grass availability in a pasture-based spring calving dairy system. *Livest. Sci.* 220, 74–82. <https://doi.org/10.1016/j.livsci.2018.12.004>
- Widowski, T.M., 2001. Shade-Seeking Behavior of Rotationally-Grazed Cows and Calves in a Moderate Climate, in: *Livestock Environment VI, Proceedings of the 6th International Symposium 2001*. Presented at the Livestock Environment VI, Proceedings of the 6th International Symposium 2001, American Society of Agricultural and Biological Engineers. <https://doi.org/10.13031/2013.7126>
- Willshire, J.A., Bell, N.J., 2009. An Economic Review of Cattle Lameness 17, 136–141.
- Witten, I.H., Frank, E., 2011. *Data Mining: Practical Machine Learning Tools and Techniques*. Elsevier. <https://doi.org/10.1016/C2009-0-19715-5>

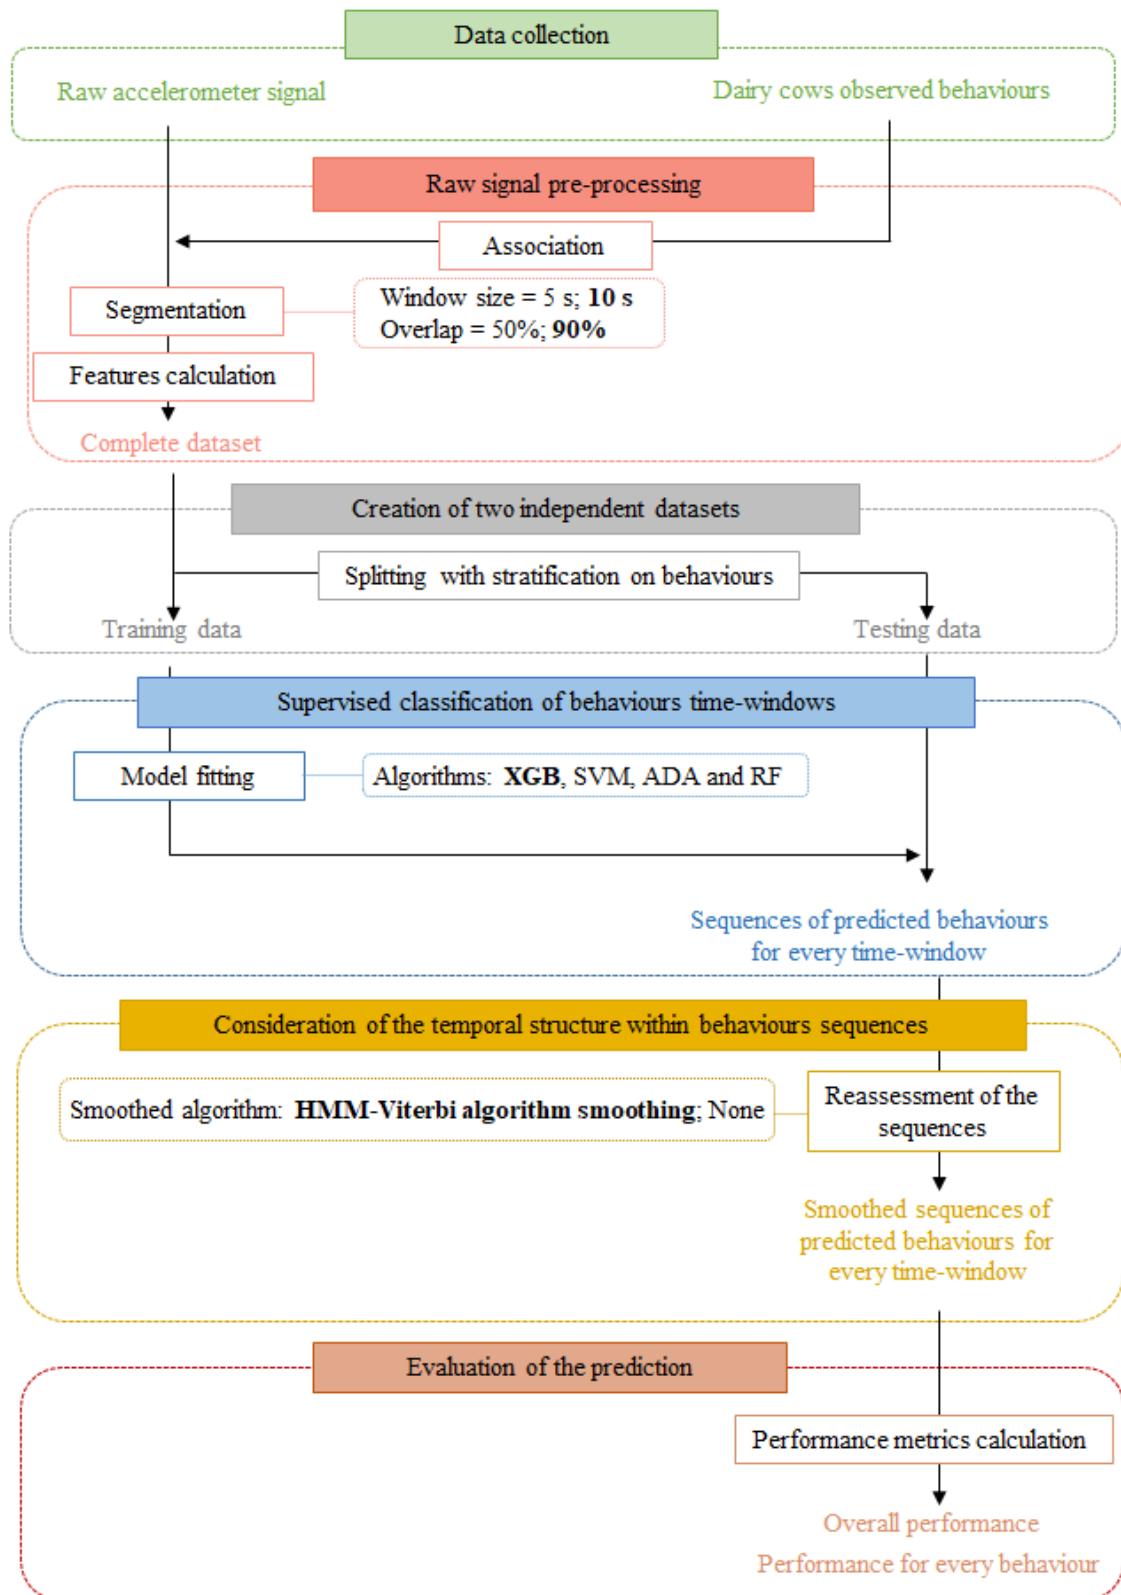
Appendices

ID cow	Parity	Days in milk
6244	1	33
6237	1	93
6220	1	111
6196	1	164
6224	1	165
6178	1	178
6219	1	181
6221	1	200
6214	1	223
6207	1	252
6189	1	276
6193	1	289
6206	1	300
6216	1	307
6203	1	327
6165	1	329
6199	1	355
6186	1	382
6177	1	432
6180	1	433
6158	1	533
6076	1	590
6062	1	959
6190	2	7
6099	2	96
6156	2	98
6167	2	135
6166	2	166
6157	2	181
6159	2	196
6130	2	237
6111	2	264
6100	2	327
6063	2	332
6137	2	352
6122	2	446
6097	2	455
6152	3	5
5997	3	43
6087	3	89
5988	3	93
6074	3	101
6054	3	103

6095	3	115
6092	3	175
6050	3	196
6048	3	220
6077	3	220
6089	3	221
6044	3	303
6007	3	309
6041	3	313
6047	3	333
6035	3	337
6066	3	366
6015	3	380
5958	3	721
5992	4	5
6017	4	7
6005	4	75
5981	4	76
5994	4	148
5929	4	155
5947	4	273
5968	4	367
5887	4	385
5898	5	166
5926	5	269
5798	5	394
5819	6	132
5744	7	228

		Mean	Standard Deviation	Minimum	Maximum
Herd	Parity	2.5	1.4	1	7
	Days in milk	250	167	5	959
Selected cows	Parity	2.7	1.6	1	7
	Days in milk	209	165	43	959

Appendix A. Parity and days in milk of the herd and of the selected cows with the associated summary metrics. The cows selected for the experiment are those in bold.



Appendix B. Method carried out during a previous study to develop an appropriate procedure to predict the range of the main behaviours of dairy cows at pasture.

Note: The techniques leading to the best performance (accuracy: 0.98; Cohen's Kappa: 0.96) are written in bold and constituted the methodological framework used in the present study

Some different types of pasture characteristics were correlated as *H2* and *MS1 MS1* (Figure 2 (a) and Figure 2 (c)). All the pasture characteristics concerned by such correlations were also identified using the clusters of the HAC. Correlations between different types of pasture characteristics led to a repetition of the same information within a same row of the dataset and thus to a potential misinterpreting of the effect of these pasture characteristics. As gathering these characteristics (Table 1.) was not possible, we condensed the information on a single characteristic for the entire combination. The characteristics highly correlated within the same combination were either kept to represent the substantial information within the combination, either substituted by the reference level. In this way, the combination of pasture characteristics was summarized by a single characteristic representative of the combination. If dairy cows spent more time in these zones, then the effect of the characteristic representative of the combination will be significant. However, this process of re-affectation should be obviously considered for the model interpretation. Three and four combinations were concerned in PG and TG, respectively. The applied re-affectations for these particular combinations were presented in the following table.

Combination	Type of pasture characteristics	Before re-affectation	After re-affectation
PG			
1	Soil moisture	MS1	MS1
	Hedges	Hedges_MS1	<i>None</i>
2	Slope	Steep	<i>Low</i>
	Botanical classes	Class_Slp	Class_Slp
3	Botanical classes	Class_3	<i>Class_4</i>
	Hedges	H9	H9
TG			
1	Hedges	H2	H2
	Slope	Presence	<i>Absence</i>
	Botanical classes	<i>Class_2</i>	<i>Class_2</i>
2	Boundaries	Bnd_AMS	Bnd_AMS
	Botanical classes	Class_3	<i>Class_2</i>
3	Boundaries	F3	F3
	Botanical classes	Class_1	<i>Class_2</i>
4	Boundaries	F4	F4
	Botanical classes	Class 1	<i>Class_2</i>

Appendix C. Method used to manage the correlations between different types of pasture characteristics.

Note: the reference levels are written in italics

Effect		Overall	Grazing	Walking	Ruminating - Lying	Ruminating - Standing	Resting - Lying	Resting - Standing	
Pasture	PG								
Day of grazing	Sign. ¹	*	***	**	**	†	*	0.45	
	mean ± se	Day 1	45.8 ^a ± 5.5	18.4 ^a ± 3.5	1.8 ^a ± 0.3	8.5 ^a ± 1.3	2.0 ^a ± 0.3	8.6 ^a ± 1.3	1.9 ^a ± 0.3
		Day 2	59.4 ^c ± 5.5	22.7 ^b ± 3.5	1.9 ^a ± 0.3	12.8 ^b ± 1.3	2.0 ^a ± 0.3	13.0 ^b ± 1.3	2.0 ^a ± 0.3
		Day 3	49.0 ^{ab} ± 5.5	19.1 ^{ab} ± 3.5	2.3 ^{ab} ± 0.3	9.3 ^a ± 1.3	2.6 ^a ± 0.3	8.7 ^a ± 1.3	2.5 ^a ± 0.3
		Day 4	52.5 ^{abc} ± 5.5	20.1 ^{ab} ± 3.5	2.8 ^b ± 0.3	10.8 ^{ab} ± 1.3	2.1 ^a ± 0.3	9.9 ^{ab} ± 1.3	2.0 ^a ± 0.3
		Day 5	57.2 ^{bc} ± 5.5	26.9 ^c ± 3.5	2.0 ^a ± 0.3	10.3 ^{ab} ± 1.3	2.2 ^a ± 0.3	9.1 ^a ± 1.3	2.2 ^a ± 0.3
Pasture	TG								
Day of grazing	Sign. ¹	*	***	0.60	**	*	*	0.21	
	mean ± se	Day 1	7.6 ^a ± 3.6	5.4 ^a ± 2.1	0.5 ^a ± 0.2	0.7 ^a ± 0.6	0.7 ^a ± 0.3	1.2 ^a ± 0.3	0.7 ^a ± 0.3
		Day 2	16.4 ^{bc} ± 3.6	12.3 ^{bc} ± 2.1	0.6 ^a ± 0.2	1.4 ^{ab} ± 0.6	1.4 ^a ± 0.3	0.9 ^a ± 0.3	1.2 ^a ± 0.3
		Day 3	10.4 ^{ab} ± 3.6	8.2 ^{abc} ± 2.1	0.4 ^a ± 0.2	1.7 ^{ab} ± 0.6	0.4 ^a ± 0.3	0.4 ^a ± 0.3	0.7 ^a ± 0.3
		Day 4	19.1 ^c ± 3.6	13.2 ^c ± 2.1	0.7 ^a ± 0.2	3.4 ^b ± 0.6	0.9 ^a ± 0.3	1.0 ^a ± 0.3	1.2 ^a ± 0.3
		Day 5	8.4 ^{ab} ± 3.6	6.6 ^{ab} ± 2.1	0.4 ^a ± 0.2	1.4 ^a ± 0.3	0.4 ^a ± 0.3	0.3 ^a ± 0.3	0.6 ^a ± 0.3

Appendix D. ANOVA results: effect of the day on the overall time and on the time-budget of every behaviour for PG and TG

Significant levels: *** P < 0.001; ** P < 0.01; * P < 0.05; † P < 0.1

¹Effects of the day of grazing

^{a-c} distinguish adjusted means that are different for the day of grazing (P < 0.05, Tukey's pairwise comparison).

The means are expressed in seconds per combination (equivalent surface unit: 8*8 m), per cow and per day

	Groups	Variance	Standard deviation
Pasture	PG		
Overall	Cow	131.7	11.5
	Residual	12005.5	109.6
Grazing	Cow	53.6	7.32
	Residual	2181.8	46.7
Walking	Cow	1.0	1.0
	Residual	74.1	8.6
Ruminating - Lying	Cow	4.3	2.1
	Residual	1702.7	41.3
Ruminating - Standing	Cow	0.6	0.8
	Residual	73.2	8.6
Resting - Lying	Cow	2.7	1.7
	Residual	1788.7	42.3
Resting - Standing	Cow	0.6	0.8
	Residual	60.3	7.8
Pasture	TG		
Overall	Cow	28.2	5.3
	Residual	2817.6	53.1
Grazing	Cow	17.3	4.2
	Residual	1459.4	38.2
Walking	Cow	0.0	0.0
	Residual	16.9	4.1
Ruminating - Lying	Cow	0.7	0.8
	Residual	164.4	12.8
Ruminating - Standing	Cow	0.2	0.4
	Residual	35.3	5.9
Resting - Lying	Cow	0.6	0.8
	Residual	37.5	6.1
Resting - Standing	Cow	0.4	0.6
	Residual	44.0	6.6

Appendix E. Results associated to the random effects on the overall time and time-budgets in PG and TG.

Effect		Overall	Grazing	Walking	Ruminating - Lying	Ruminating - Standing	Resting - Lying	Resting - Standing	
<i>Intercept</i>	Est. ± se	3.2 ± 4.4	5.1 ± 2.3	0.5 ± 0.3	-0.1 ± 1.0	0.2 ± 0.2	-0.2 ± 1.0	0.7 ± 0.2	
	Sign.	0.46	*	†	0.91	0.45	0.86	**	
Day	Day 2	Est. ± se	1.4 ± 3.3	4.3 ± 1.4	0.2 ± 0.3	4.3 ± 1.2	0.03 ± 0.3	4.4 ± 1.3	
		Sign.	***	**	0.65	***	0.90	***	
	Day 3	Est. ± se	3.2 ± 3.3	0.8 ± 1.4	0.4 ± 0.3	0.8 ± 1.2	0.6 ± 0.3	0.2 ± 1.3	
		Sign.	0.33	0.57	†	0.53	*	0.89	
	Day 4	Est. ± se	6.6 ± 3.3	1.7 ± 1.4	0.9 ± 0.3	2.3 ± 1.2	0.1 ± 0.3	1.3 ± 1.3	
		Sign.	*	0.21	***	†	0.6	0.30	
	Day 5	Est. ± se	1.3 ± 3.3	8.5 ± 1.4	0.2 ± 0.3	1.8 ± 1.2	0.3 ± 0.3	0.5 ± 1.3	
		Sign.	***	***	0.44	0.14	0.3	0.70	
Trees	T1	Est. ± se	20.5 ± 7.4	4.0 ± 3.2	0.1 ± 0.5	5.7 ± 2.6	2.4 ± 0.6	5.5 ± 2.7	2.1 ± 0.5
		Sign.	**	0.21	0.91	*	***	*	***
	T2	Est. ± se	93.8 ± 6.1	30.8 ± 2.7	2.5 ± 0.5	26.0 ± 2.1	3.2 ± 0.4	27.7 ± 2.2	4.4 ± 0.4
		Sign.	***	***	***	***	***	***	***
	T3	Est. ± se	16.7 ± 4.9	8.4 ± 2.1	1.1 ± 0.4	2.9 ± 1.7	1.6 ± 0.3	1.8 ± 1.7	1.0 ± 0.3
		Sign.	***	***	**	†	***	0.30	**
Hedges	H1	Est. ± se	0.0 ± 4.6	0.8 ± 2.0					0.0 ± 0.3
		Sign.	0.99	0.69					0.95
	H5	Est. ± se	1.7 ± 6.2	0.3 ± 2.7					0.0 ± 0.4
		Sign.	0.78	0.90					0.91
	H6	Est. ± se	-8.5 ± 4.5	-3.9 ± 2.0					0.0 ± 0.3
		Sign.	†	†					0.95
	HN	Est. ± se	-1.4 ± 4.5	-7.5 ± 2.0					-0.9 ± 0.3
		Sign.	**	***					**
	H9	Est. ± se	5.7 ± 4.6	4.3 ± 2.0					-1.3 ± 0.3
		Sign.	0.21	*					***
	H10	Est. ± se	2.4 ± 5.0	0.1 ± 2.2					1.0 ± 0.4
		Sign.	0.21	0.95					0.77
Boundaries	PA	Est. ± se		-2.9 ± 3.2					
		Sign.		0.35					
	F1	Est. ± se		-6.6 ± 2.7					
		Sign.		*					
Slope	Mod.	Est. ± se	5.6 ± 2.7	2.7 ± 1.2	0.2 ± 0.2				
		Sign.	*	*	0.32				
	Steep	Est. ± se	8.9 ± 3.4	5.7 ± 1.5	0.6 ± 0.2				
		Sign.	**	***	*				
Soil moisture	MS1	Est. ± se	-8.3 ± 3.9	-3.5 ± 1.7				-1.0 ± 0.3	
		Sign.	*	*				***	
	MS2	Est. ± se	12.6 ± 5.4	8.6 ± 2.4				0.4 ± 0.4	
		Sign.	*	***				0.25	
Botanical classes	Class 3	Est. ± se	11.8 ± 3.9	6.8 ± 1.7	0.6 ± 0.3			0.0 ± 0.3	
		Sign.	**	***	*			0.89	
	Class 5	Est. ± se	2.8 ± 3.4	-1.3 ± 1.5	-0.3 ± 0.2			0.6 ± 0.2	
		Sign.	0.4	0.36	0.18			*	
	Class_MA	Est. ± se	6.6 ± 4.0	1.9 ± 1.8	-0.1 ± 0.2			0.6 ± 0.3	
		Sign.	0.1	0.27	0.62			*	
	Class_Slp	Est. ± se	5.8 ± 4.5	2.3 ± 1.9	0.4 ± 0.3			0.4 ± 0.3	
		Sign.	0.19	0.26	0.21			0.26	

Appendix F. Definitive results models: estimates and significance levels associated to each pasture characteristics and the day of grazing for PG. Note: Significant levels: *** P < 0.001; ** P < 0.01; * P < 0.05; † P < 0.1

Effect		Overall	Grazing	Walking	Ruminating - Lying	Ruminating - Standing	Resting - Lying	Resting - Standing	
<i>Intercept</i>	Est. ± se	11.7 ± 3.2	7.7 ± 1.9	0.4 ± 0.1	0.1 ± 0.6	0.3 ± 0.3	1.2 ± 0.3	0.5 ± 0.2	
	Sign.	***	***	***	0.80	0.32	***	*	
Day	Day 2	Est. ± se	8.8 ± 3.1	6.9 ± 2.2		0.8 ± 0.7	0.8 ± 0.3	-0.4 ± 0.3	
		Sign.	**	**		0.3	*	0.29	
	Day 3	Est. ± se	2.8 ± 3.1	2.8 ± 2.2		1.0 ± 0.7	-0.07 ± 0.3	-0.8 ± 0.3	
		Sign.	0.36	0.21		0.2	0.82	*	
	Day 4	Est. ± se	11.5 ± 3.1	7.8 ± 2.2		2.7 ± 0.7	0.4 ± 0.3	-0.3 ± 0.3	
		Sign.	***	***		***	0.22	0.42	
	Day 5	Est. ± se	0.8 ± 3.1	1.2 ± 2.2		0.7 ± 0.7	0.4 ± 0.3	-0.9 ± 0.3	
		Sign.	0.80	0.58		0.33	0.22	*	
Hedges	H1	Est. ± se	-2.5 ± 3.5	-0.2 ± 2.2					
		Sign.	0.47	0.94					
	H2	Est. ± se	-10.7 ± 4.0	-7.1 ± 2.5					
		Sign.	**	**					-0.1 ± 0.3
Boundaries	F1	Est. ± se	-5.4 ± 3.0				-0.2 ± 0.3		0.80
		Sign.	†				0.53		-0.2 ± 0.3
	Bnd_AMS	Est. ± se	-2.9 ± 3.3				-0.1 ± 0.3		0.59
		Sign.	0.38				0.77		0.0 ± 0.6
	F3	Est. ± se	-1.5 ± 5.2				0.1 ± 0.5		0.94
		Sign.	0.78				0.86		1.7 ± 0.4
	F4	Est. ± se	7.8 ± 4.0				1.4 ± 0.4		***
		Sign.	†				***		
Slope	Presence	Est. ± se							
		Sign.							
Botanical classes	Class 1	Est. ± se	-4.8 ± 3.9	-3.8 ± 2.7	-0.2 ± 0.3	0.1 ± 0.8			
		Sign.	0.21	0.14	0.4	0.95			
	Class 3	Est. ± se	6.8 ± 2.9	4.0 ± 1.8	0.5 ± 0.2	1.5 ± 0.6			
		Sign.	*	*	**	**			

Appendix G. Definitive results models: estimates and significance levels associated to each pasture characteristics and the day of grazing for TG.

Note: Significant levels: *** P < 0.001; ** P < 0.01; * P < 0.05; † P < 0.1

Chapitre 6 – Discussion

Ce travail visait à développer un cadre méthodologique permettant de remonter automatiquement (sans intervention humaine) le comportement des vaches laitières au pâturage et de façon continue (haute fréquence d'acquisition) à partir de capteurs accéléromètres et GPS afin de lever les deux principaux verrous au développement d'outils numériques pour le pâturage, à savoir :

- (1) Le faible nombre de comportements pouvant être prédits de manière fiable
- (2) La validité des modèles développés à l'échelle de la période et de l'individu

Ce travail a été réalisé en vue de répondre à deux questions de recherche :

- (1) Quelle combinaison de méthodes (traitement du signal, algorithmes de classification, etc.) peut permettre de classifier le comportement des vaches laitières au pâturage en venant lever les deux verrous exposés dans la littérature ?
- (2) Quel est le potentiel du cadre méthodologique combiné à des données de position des animaux pour répondre au moins à l'une des applications envisagées ? A savoir :
 - Evaluer l'état de la ressource sur la parcelle en vue de faciliter la prise de décision des changements de parcelles en pâturage tournant.
 - Assurer un suivi automatisé du bien-être et de la santé des animaux au pâturage.

Partie 1. Mise en place d'un cadre méthodologique pour une prédiction robuste des comportements des vaches laitières, une approche à fort potentiel pour répondre à des problématiques autour du pâturage.

1. Prédiction robuste de l'ensemble des comportements principaux des vaches laitières au pâturage à partir de données accéléromètres

1.1 Amélioration des performances de prédiction des comportements des vaches laitières au pâturage par rapport à l'existant

Le présent travail a permis de mettre en place un cadre méthodologique garantissant une prédiction robuste de l'ensemble des comportements principaux des vaches laitières au pâturage. Les comportements de pâturage, de marche, de repos et de rumination, avec prise en compte des postures « couché » et « debout », sont prédits avec un pourcentage de bon classement de 98 % et un Kappa de Cohen de 0.96 sur un jeu de données test. Les sensibilités et spécificités sont supérieures à 0.90 pour tous les comportements, à l'exception du comportement "repos en position debout" (sensibilité : 0.82) et du comportement "marche" (sensibilité : 0.84). Au regard des performances obtenues, le présent travail a permis (1) d'élargir le spectre des comportements des vaches laitières prédits de manière fiable et (2) de valider les modèles inclus dans le cadre méthodologique à l'échelle de la période d'observation.

1.1.1 Une prédiction fiable pour une large gamme de comportements

Comme expliqué dans le premier chapitre, un suivi automatisé et continu du comportement des vaches laitières au pâturage constitue une approche pertinente pour appréhender l'état de la ressource sur la parcelle (Werner et al., 2019) et pour détecter des défauts de confort chez les animaux (O'Driscoll et al., 2019), à condition de remonter suffisamment d'informations (comportement alimentaire, statique, distinction des postures, etc.). Alors que la littérature mettait jusqu'ici en exergue des performances de prédiction dégradées dès lors qu'une diversité de comportements était considérée (Alvarenga et al., 2016; Martiskainen et al., 2009), le cadre méthodologique mis en œuvre au cours de ce travail affiche au contraire de remarquables performances pour chacun des six comportements étudiés. En garantissant une prédiction satisfaisante de chacun des comportements principaux des vaches laitières, incluant à la fois comportement alimentaire, dynamique et statique avec distinction des postures « couché » et

« debout », le cadre méthodologique proposé vient lever le premier verrou majeur au développement d'outils d'aide à la détection d'évènements au pâturage (Dutta et al., 2015; Rushen et al., 2012).

1.1.2 Validité des modèles à l'échelle de la période d'observation

Comme expliqué dans le Chapitre 1, les études qui utilisent des fenêtres temporelles issues d'une même vache à la même période d'observation pour entraîner et valider les modèles (Lush et al., 2018 ; Martiskainen et al., 2009) ont nécessairement des performances optimistes et non représentatives de ce qui sera obtenu en situation réelle (Rahman et al., 2018).

Dans notre étude, un effort considérable a été réalisé lors de la phase expérimentale afin de collecter des données accéléromètres sur 86 animaux issus de quatre élevages différents. Les animaux ont été observés en parallèle sur plusieurs sessions, aboutissant à 57 heures d'observation au total. De cette manière, le jeu de données collecté a permis (1) d'entraîner les algorithmes avec un jeu de données représentatif de la variabilité intra et inter individuelle soulignée par plusieurs auteurs (Arcidiacono et al., 2017; Rahman et al., 2018) et (2) de valider les modèles avec des fenêtres issues de périodes d'observation différentes de celles utilisées pour l'entraînement des modèles. Les performances en sortie du cadre méthodologique restent ainsi supérieures à celles de la littérature tout en ayant mis en œuvre une technique de validation adaptée.

1.2 Retour sur les techniques et algorithmes mis en œuvre pour aboutir aux très bonnes performances

La combinaison des techniques et algorithmes utilisés est présentée dans la Figure 17. Les différentes étapes algorithmiques qui permettent d'atteindre les très bonnes performances générales de nos méthodes de prédiction sont rappelées et discutées dans ce paragraphe.

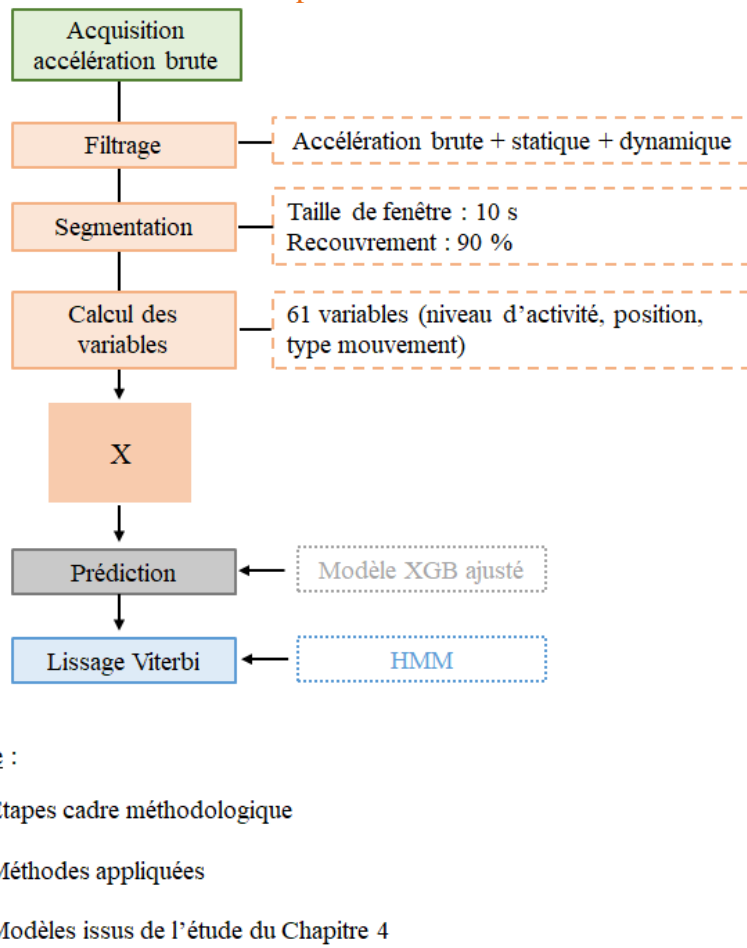


Figure 17. Cadre méthodologique développé pour prédire les six principaux comportements des vaches laitières au pâturage

❖ Mise en œuvre d'une configuration de traitement du signal adaptée

L'accélération brute a été conservée dans l'analyse. Les séries OBDA et VeDBA ont également été calculées à partir de la composante dynamique extraite *via* un filtre passe haut à 0.3 Hz. Les séries *pitch* et *roll* ont aussi été calculées à partir de la composante statique isolée *via* un filtre passe-bas à la même fréquence (Figure 10). Un recouvrement de 90 % a été choisi pour la segmentation du signal à partir des résultats des études menées aux Chapitres 3 et 4. Comme expliqué par Bersch et al. (2014), le recouvrement permet de générer de nouvelles fenêtres de signal, améliorant ainsi l'apprentissage des modèles de classification. A ce propos, cette technique est notamment recommandée lorsque les observations viennent à manquer (Andriamandroso et al., 2017). Une taille de fenêtre de 10 secondes a été retenue à partir des résultats des Chapitres 3 et 4.

Dans le contexte propre à notre étude, cette taille de fenêtre semble répondre au compromis entre une taille de fenêtre suffisamment longue pour être représentative des comportements, et suffisamment courte pour éviter que plusieurs comportements ne soient exprimés au sein d'une même fenêtre (fenêtre hétérogène⁴).

❖ Utilisation d'un algorithme de classification performant

Le classifieur ayant abouti aux meilleures performances de classification dans l'étude menée au Chapitre 4 est l'algorithme d'eXtreme Gradient Boosting. Ce résultat rejoint les récentes études ayant mis en jeu cet algorithme, quel que soit le domaine d'application (Ayumi, 2016; Babajide Mustapha and Saeed, 2016; Shi et al., 2019). Comme expliqué dans l'Annexe X, cette méthode ensembliste de ML se base sur plusieurs arbres de régression pour prédire la classe associée à un nouvel individu. En particulier, cette méthode consiste à :

- (1) Créer un arbre de régression sur les résidus de l'arbre précédent, l'objectif étant d'améliorer successivement la prédiction des régions mal prédites par les arbres qui précèdent (principe du *gradient boosting*).
- (2) Identifier à chacune des séparations de l'arbre en cours de construction le nœud qui maximise le gain, *i.e.*, qui maximise la similarité au sein des nœuds enfants à partir du nœud parent.
- (3) Limiter le sur-ajustement :
 - En ne choisissant qu'une partie des variables et échantillons (*i.e.* résidus dans ce contexte) pour construire l'arbre à chaque itération.
 - En fixant la profondeur maximale de l'arbre et le nombre minimum d'échantillons dans les feuilles.
 - En utilisant un paramètre qui conditionne l'élagage de chacune des feuilles en fonction du gain associé au nœud dont elles sont issues.

La méthode d'eXtreme Gradient Boosting s'appuie donc sur l'algorithme de *gradient boosting* (1) mais en optimisant l'arbre de régression choisi à chaque étape (2) et en limitant davantage le sur-ajustement (3). Ces éléments contribuent certainement à expliquer les remarquables performances de cette méthode.

⁴Les fenêtres hétérogènes ne sont pas appropriées pour entraîner des modèles de classification et sont donc supprimées lors de l'étape de traitement du signal brut. Ceci aboutit nécessairement à une réduction du volume du jeu de données, un point pénalisant pour l'apprentissage des modèles (Andriamandroso et al., 2017). En application sur le terrain, les fenêtres hétérogènes pénalisent également la prédiction puisque ces fenêtres ne sont pas exclusivement représentatives des comportements pour lesquels les modèles ont été entraînés. Il convient donc de choisir une taille de fenêtre suffisamment courte pour éviter de générer des fenêtres hétérogènes.

- ❖ Prise en compte de la structure temporelle au sein d'une séquence de comportements

Les résultats issus de l'étude du Chapitre 4 ont souligné l'intérêt d'un lissage des comportements prédits par les modèles de ML *via* l'algorithme de Viterbi. Comme expliqué dans l'Annexe XI, ce modèle utilise la structure temporelle au sein d'une séquence d'états cachés pour identifier la séquence qui semble la plus probable à partir d'un HMM dont les paramètres sont connus. Dans le HMM choisi pour cette étude, les états cachés sont les comportements observés et les états observés sont les comportements prédits par les modèles de ML. La matrice de transition et les probabilités initiales ont été obtenues de façon empirique tandis que la matrice d'émission du HMM a été établie à partir de la matrice de confusion des algorithmes de ML. De cette manière, les corrections proposées par Viterbi tiennent compte conjointement (1) de la structure temporelle présente au sein d'une séquence continue de comportements et (2) des erreurs propres au modèle de classification supervisée. Le cadre méthodologique s'appuie donc sur la complémentarité entre les méthodes de ML et les modèles probabilistes. Cette approche est particulièrement intéressante pour prédire des comportements pour lesquels il n'existe a priori aucune caractéristique pertinente pour les discriminer. On observe ainsi un gain de sensibilité pour le comportement « repos en position debout » (+ 4 %), un comportement confondu avec le comportement « repos en position couché » puisque le niveau d'activité et la position de la tête sont similaires dans les deux cas (Martiskainen et al., 2009).

2. Potentiel du cadre méthodologique combiné à des données de géolocalisation pour les applications envisagées

2.1 Suivi du bien-être des animaux au pâturage

Dans le Chapitre 5, le cadre méthodologique couplé à des données de position des animaux a permis de mettre en lien les comportements exprimés avec les caractéristiques botaniques et structurelles de la parcelle ainsi qu'avec l'environnement direct des vaches laitières. L'adaptation des animaux à un challenge interne ou externe s'exprimant initialement par une modification du comportement (Wechsler, 1995), l'approche mise en œuvre devrait permettre d'observer le changement attendu, en lien avec des conditions de pâturage non appropriées ou tout autre évènement défavorable au bien-être des vaches laitières. En particulier, le comportement des animaux pourrait être exploré de façon exhaustive selon différentes

conditions de pâturage, en s'intéressant à la fois à l'évolution du comportement alimentaire et de repos (position couché *versus* debout), à la dynamique du déplacement et à l'utilisation évolutive des caractéristiques structurelles et botaniques de la parcelle par les animaux. Cette approche devrait permettre d'aller plus loin que l'existant, les études sur ce sujet remontant exclusivement les temps d'expression et le nombre d'occurrences associées à chacune des activités (O'Driscoll et al., 2019; Werner et al., 2019). Le cadre méthodologique couplé à des données de position est certainement un moyen d'identifier des *patterns* spécifiques liés à des événements stressants au pâturage comme un stress physique ou thermique (Riaboff et al., 2018; Widowski, 2001), la faim ou la soif, la détresse liée à un événement extérieur ou encore la douleur, répondant ainsi à la plupart des libertés fondamentales du bien-être animal ("Farm Animal Welfare Committee (FAWC)," 2011).

2.2 Détection des troubles de santé

L'appréhension des troubles de santé n'a pas été abordée dans le présent travail mais l'approche développée devrait permettre de détecter certaines pathologies, au même titre qu'un défaut de confort chez les animaux. Une étude réalisée à partir du cadre méthodologique développé sur la détection des boiteries au pâturage (Petiot, 2019) va d'ailleurs dans ce sens. Les résultats issus de ce dernier travail confirment en effet un changement de comportement des animaux au pâturage en cas de boiteries, en lien avec une diminution du temps dédié à l'ingestion (- 8.8 %) et une augmentation du temps passé couché (+ 6.2 %). Ces résultats confirment ceux obtenus avec des animaux en bâtiment (Chapinal et al., 2009; Yunta et al., 2012) et justifient de remonter à la fois des informations sur le comportement alimentaire et sur les postures des vaches laitières pour améliorer la sensibilité et la spécificité des outils de détection de boiteries existants (Willshire and Bell, 2009). Les quelques systèmes embarqués commercialisés pour détecter les boiteries sont en effet basés sur des podomètres, comme l'outil AfiTagII® de Afimilk®. Les informations remontées sont donc limitées au nombre de pas et au temps passé dans chacune des postures, expliquant certainement les performances de détection médiocres de ces outils (Rutten et al., 2013). Le cadre méthodologique couplé à des données de position constitue donc un support pertinent au développement d'outils d'aide à la détection d'événements de santé au pâturage, tout au moins pour la détection de boiteries.

2.3 Optimisation de la gestion du pâturage

Comme expliqué dans le Chapitre 1, un outil permettant de détecter rapidement les situations dans lesquelles la biomasse est insuffisante dans les prairies en pâturage tournant permettrait

de s'affranchir des mesures de hauteur d'herbe qui sont laborieuses et chronophages (French et al., 2015). L'approche développée dans le présent travail a permis de mettre en exergue une évolution des comportements exprimés au cours des cinq jours de pâturage (Annexe D et Annexe F du Chapitre 5) et au cours de la journée (Riaboff et al., 2018). Même si la biomasse n'a jamais été limitante dans ces deux dernières études pour observer un changement de comportement associé à la diminution de l'herbe disponible, l'approche développée pourrait néanmoins être utilisée afin d'explorer le changement de comportement attendu lorsque la ressource devient limitante. Ceci permettrait (1) de confirmer les modifications observées dans la littérature (Delagarde et al., 2010; Werner et al., 2019) et (2) d'identifier d'autres *patterns* spécifiques à l'insuffisance de la biomasse, l'approche développée permettant d'explorer le comportement et la dynamique des animaux de façon plus exhaustive que ce qui est entrepris dans la littérature. Une telle étude permettrait de confirmer le potentiel de l'approche en vue de concevoir un outil d'aide à la détection de l'état de la ressource sur la parcelle par la suite. Dans le cas où le robot de traite est utilisé, l'approche développée devrait également permettre de mieux comprendre les relations et hiérarchies sociales au sein du troupeau et leur impact en termes d'utilisation du robot en vue d'optimiser l'utilisation de celui-ci.

Partie 2. Conception d'un outil d'aide à la décision pour le pâturage à partir du cadre méthodologique développé

La preuve de concept réalisée au Chapitre 5 et les réflexions menées autour des applications potentielles justifie de s'intéresser désormais aux étapes suivantes du développement de l'outil d'aide à la décision. En particulier, deux volets majeurs doivent être considérés : un volet développement et un volet instrumentation.

1. Volet développement : de la prédiction des comportements à la détection d'évènements au pâturage

1.1 Amélioration de la prédiction des modèles avec des fenêtres issues de nouvelles vaches laitières

- ❖ Baisse des performances obtenues avec une validation à l'échelle de l'individu

Le cadre méthodologique mis en place aboutit à de remarquables performances de prédiction lorsque les modèles sont validés à l'échelle de la période d'observation. Néanmoins, les performances se dégradent lorsque les modèles sont validés à l'échelle de l'individu (pourcentage de bon classement : 85 % ; Kappa de Cohen de 0.76), une limite certaine au développement d'outils d'aide à la décision puisque ceux-ci doivent être fonctionnels quel que soit l'animal équipé. Comme illustré dans la Figure 18, la baisse de performance provient de la confusion prononcée entre les comportements de repos/rumination en position « debout » et « couché ». Ceci se traduit par une diminution de la sensibilité des comportements « repos en position debout » et « rumine en position debout ».

	Sensibilité / Spécificité		Prédiction						
	Sensibilité	Spécificité	Référence	Pâture	Repos - Couché	Rumine - Couché	Repos - Debout	Rumine - Debout	Marche
Pâture	0.99	0.99	Pâture	2133	0	0	0	0	18
Repos - Couché	0.91	0.95	Repos - Couché	0	649	4	64	0	0
Rumine - Couché	0.93	0.96	Rumine - Couché	0	3	671	10	37	0
Repos - Debout	0.39	0.98	Repos - Debout	5	158	9	113	3	2
Rumine - Debout	0.52	0.99	Rumine - Debout	0	0	146	0	157	0
Marche	0.67	1	Marche	17	0	0	9	1	56

Figure 18. Baisse de sensibilité des comportements de repos en position debout dans le cas d'une validation à l'échelle de l'individu liée à une confusion avec les comportements de repos en position couchée

❖ Voies d'amélioration à explorer

Comme expliqué dans les chapitres précédents, la discrimination des positions « couché » et « debout » est particulièrement difficile à appréhender avec un accéléromètre au collier puisque les niveaux d'activité et la position de la tête de l'animal sont sensiblement les mêmes (Hamalainen et al., 2011). L'analyse de la distribution des variables réalisée au cours de l'étude du Chapitre 4 (*résultats non fournis*) confirme les explications proposées dans la littérature puisqu'aucune variable discriminante n'a pu être identifiée pour classer ces deux comportements. Il semble donc plus judicieux de s'intéresser désormais à d'autres variables potentielles pour discriminer les comportements mal prédits plutôt que de remettre en question les algorithmes en eux-mêmes.

Certains auteurs recommandent de positionner deux capteurs accéléromètres à deux positions différentes pour obtenir des variables complémentaires, aboutissant à une classification satisfaisante de l'ensemble des comportements (Benaissa et al., 2017). Cette approche est néanmoins plus contraignante pour les animaux et pour les éleveurs et donc difficilement transférable sur le terrain.

Plusieurs auteurs proposent quant à eux de combiner des données accéléromètres avec des données issues de capteurs différents. Andriamandroso et al. (2017) ont par exemple utilisé la vitesse de rotation issue d'un gyromètre pour classer les comportements de pâturage et de rumination, en complément de l'accélération statique. En reconnaissance des activités humaines, Shoaib et al. (2013) ont montré une amélioration de la sensibilité globale pour chacun des modèles testés lorsque les données de l'accéléromètre ont été associées à celles du gyromètre d'un smartphone. En particulier, la sensibilité de certaines activités spécifiques (montée et de descente d'escalier) a été largement améliorée avec le gyromètre. L'intérêt d'un gyromètre ou d'autres types de capteurs en complément de l'accéléromètre mérite donc d'être exploré.

Les comportements ponctuels « se couchent » et « se lèvent » (Hamalainen et al., 2011; Vázquez Diosdado et al., 2015) pourraient aussi être prédits à la place des comportements d'état « est couchée » et « est debout ». Cette approche n'a pas été explorée dans le présent travail en raison du faible nombre d'observations associées à ces événements. La détection des comportements « se couche » et « se lève » pourrait être couplée à un modèle probabiliste afin de prédire les postures des bovins, les probabilités de transitions entre états qui s'en suivent pouvant facilement être estimées de façon empirique. L'intérêt d'une segmentation par partitionnement ou par agrégation (Keogh et al., 2001) mériterait également d'être évalué en

vue de détecter spécifiquement ces événements. Ces techniques permettraient de générer des fenêtres bornées autour des comportements « se couche » et « se lève », une approche particulièrement intéressante compte tenu de la brièveté et de la ponctualité de ces événements.

Enfin, une alternative consisterait à prédire les postures des vaches laitières *via* une approche Bayésienne inspirée de la biomécanique, consistant à modéliser le comportement mécanique des vaches laitières, avec leurs accélérations, leurs rotations, leurs vitesses, en vue de trouver à chaque instant le comportement le plus probable.

1.2 Mise en place d'algorithmes de détection à partir des comportements prédits par le cadre méthodologique

Afin de répondre aux applications envisagées, il convient d'établir par la suite des algorithmes de détection basés sur les comportements prédits par le cadre méthodologique. Une étape de calibration spécifique à chacun des événements à détecter doit donc être réalisée. La calibration de ces algorithmes pourrait s'appréhender en deux temps :

- (1) En commençant par une analyse exploratoire afin d'identifier les comportements ou *patterns* impliqués dans la transition à partir de données expérimentales. A ce propos, la disparité des conclusions proposées dans les études qui s'intéressent au comportement des vaches laitières dans des conditions particulières (Delagarde et al., 2010; Ribeiro Filho et al., 2011) justifie de mettre en place un protocole adapté pour s'assurer de la reproductibilité des résultats obtenus (Werner et al., 2019).
- (2) En développant ensuite l'algorithme de détection sur la base des comportements et *patterns* identifiés dans l'analyse précédente. A ce propos, il est sûrement pertinent de s'inspirer prioritairement des techniques utilisées pour détecter les chaleurs chez les vaches laitières à partir de l'activité mesurée (Shahriar et al., 2016) :
 - Des techniques de seuillage arbitraire comme la règle des 3 sigmas⁵ (Zhao et al., 2013)
 - Des techniques de détection automatique des points de changement dont l'objectif est de détecter le point à partir duquel les propriétés statistiques de la séquence temporelle d'observations sont modifiées (Killick and Eckley, 2014).

⁵La règle des 3 sigmas repose sur le principe selon lequel plus de 99 % des échantillons se situent à moins de 3 fois l'écart-type par rapport à la moyenne dans le cas d'une distribution normale. Par conséquent, tous les échantillons situés en dehors de la zone définie par [moyenne - 3*écart-type ; moyenne + 3*écart-type] sont considérés comme atypiques et donc associés à l'évènement à détecter.

2. Volet instrumentation : de la détection d'évènements au pâturage à un outil finalisé

En supposant qu'il soit possible de mettre en œuvre des algorithmes de détection des évènements à partir des comportements prédits, plusieurs aspects instrumentaux nécessitent d'être abordés en vue d'assurer la fonctionnalité du système. Les principales étapes sont illustrées dans la Figure 19 et expliquées ci-après.

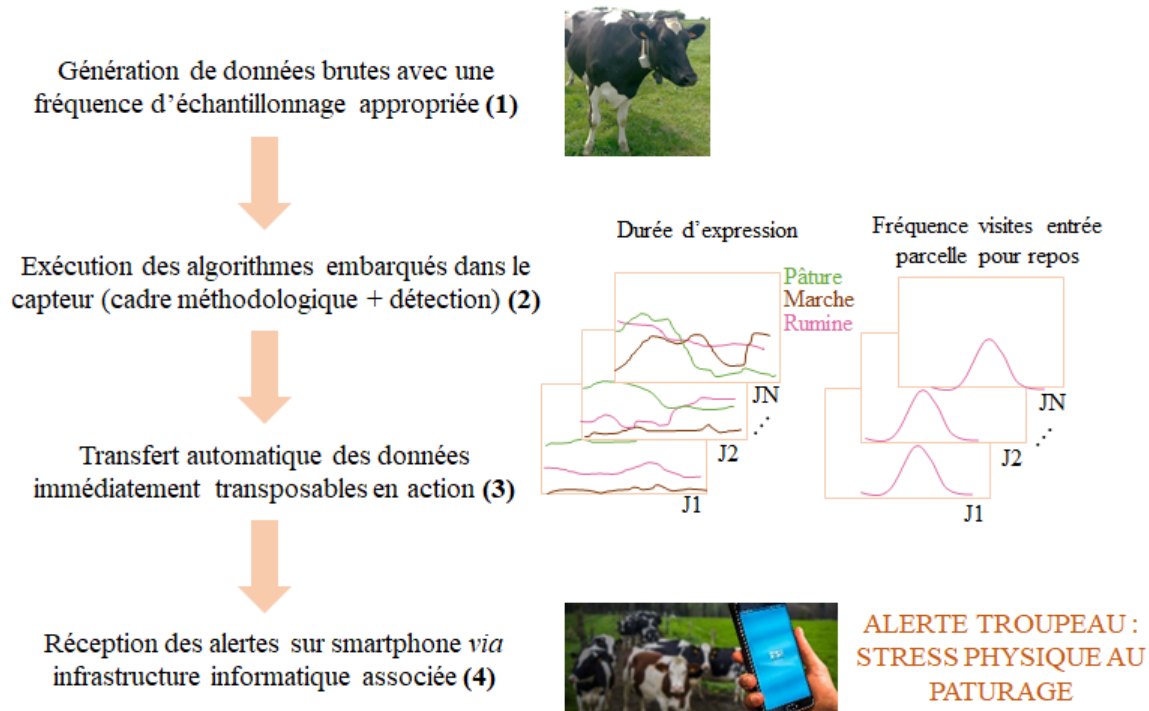


Figure 19. Volet instrumentation : étapes d'ingénierie à réaliser pour aboutir à une solution fonctionnelle

(1) Autonomie de la batterie des capteurs

A ce jour, l'autonomie est de 5 jours ce qui est potentiellement limitant pour certaines applications (recherche zootechnique, état de la ressource en système tournant, etc.). L'autonomie de la batterie étant en partie conditionnée par la fréquence d'échantillonnage, une analyse visant à sous-échantillonner le signal et à tester de nouveau les performances de prédiction des modèles doit être réalisée, comme le propose Benaissa et al. (2017). Cette analyse permettra d'identifier la fréquence compromis entre autonomie de la batterie et performance du modèle. L'autonomie du système dépend également de la complexité algorithmique, justifiant de simplifier au maximum les algorithmes sans pour autant perdre en performance.

(2) Intégration des algorithmes dans le système embarqué

Les données générées par les capteurs (accéléromètres, gyromètres, GPS) doivent d'abord être parfaitement synchronisées. Les algorithmes de prédiction ainsi que les algorithmes de détection d'évènements nécessitent ensuite d'être embarqués dans le système afin de fournir en sortie une information directement interprétable (Dolecheck et al., 2013). Un travail majeur d'ingénierie visant (1) à évaluer la compatibilité des algorithmes développés pour un système embarqué et (2) à les intégrer dans le système doit donc être considéré pour concevoir l'outil finalisé.

(3) Transfert automatique des données

Le dispositif utilisé au cours de ce travail nécessitait de récupérer les données stockées sur une carte SD par câble USB. Un travail d'ingénierie doit donc être mené en vue d'assurer un transfert automatique des données. Pour cela, les techniques de télécommunication les plus récentes permettant une grande portée, une faible consommation et un faible coût de transmission doivent être mobilisées, comme les réseaux sigfox, LoRaWAN, etc. A noter que cette étape est dépendante de celle qui précède puisqu'il convient d'exporter uniquement les données traitées et directement interprétables en vue de réduire au maximum le volume de données à transférer.

(4) Mise en place de l'infrastructure informatique

La dernière étape de conception de l'outil d'aide à la décision vise à mettre en place l'infrastructure informatique associée au système, l'objectif étant d'envoyer les alertes directement à l'éleveur *via* une application pour smartphone.

Partie 3. Portée de l'outil au-delà des strictes applications envisagées : un système au service de différentes visions de l'agriculture

1. L'agriculture moderne et postmoderne, deux visions différentes de l'agriculture (Rigolot, 2017)

1.1 L'agriculture moderne : prioriser la sécurité alimentaire tout en limitant les impacts

Le développement agricole selon la vision de l'agriculture moderne est d'abord guidé par l'objectif de sécurité alimentaire à l'échelle mondiale, avec un recentrage sur la dimension matérielle de l'agriculture et de l'alimentation. Selon cette vision moderne, l'agriculture doit d'abord fournir les apports caloriques et en protéines nécessaires pour répondre à la demande mondiale croissante, en lien avec l'essor démographique, l'urbanisation et l'augmentation des revenus dans les pays émergents (Alexandratos, 2012). Néanmoins, si les gains de production et les performances économiques ont d'abord été mis en avant, les enjeux de développement durable sont désormais bien intégrés dans cette vision de l'agriculture, comme en témoigne l'injonction à l'intensification écologique. Les concepts centraux de cette vision reposent ainsi sur l'efficience (« produire plus avec moins ») mais aussi sur la multi-performance. Cette vision semble donc compatible avec la transition agroécologique. A ce propos, la vision moderne de l'agriculture place de grands espoirs dans les nouvelles technologies (agriculture de précision, agriculture connectée, biologie prédictive, etc.) qui sont vues comme des outils supports aux performances économiques, environnementales et sociales.

1.2 L'agriculture postmoderne : assurer la souveraineté alimentaire en intégrant la diversité des contextes territoriaux

La vision de l'agriculture postmoderne place la notion de souveraineté alimentaire, qui « intègre et transcende » la sécurité alimentaire, au centre de ses préoccupations. La souveraineté alimentaire doit être comprise comme « le droit de chaque nation de maintenir et d'élaborer sa propre capacité de produire ses propres aliments de base dans le respect de la diversité productive et culturelle » (FAO, 1996). Cette vision de l'agriculture intègre ainsi la diversité des contextes territoriaux et plébiscite les systèmes agricoles ancrés dans leurs sociétés et leurs territoires (appellation d'origine, produits de terroir, commerce équitable, etc.). La vision

postmoderne prend également en compte des facteurs sociaux dans son développement comme les relations de pouvoir (Sevilla Guzmán, 2013). Pour ces raisons, la Recherche et Développement est typiquement interdisciplinaire et participative en vue d'intégrer les composantes sociales du développement. Cette vision est donc complètement compatible avec la transition agroécologique. A noter que le recours aux nouvelles technologies n'est pas nécessairement en opposition avec cette vision de l'agriculture même si une réserve est émise quant à l'usage qui en sera fait et aux impacts qui en découleront (High Level Panel of Experts on Food Security and Nutrition, 2019). L'utilisation du numérique au service de cette vision de postmoderne est discutée dans la partie suivante.

2. Un outil numérique au service de deux visions de l'agriculture qui répondent à des volets différents de la transition agroécologique.

2.1 Un outil pouvant contribuer à la multi-performance visée par l'agriculture moderne

L'outil d'aide à la décision développé au cours de ce travail de thèse peut certainement contribuer aux multi-performances visées par l'agriculture moderne, conformément aux attentes de l'élevage de précision tel que l'envisage Berckmans (2017) :

❖ Amélioration des performances animales

La remontée automatique d'information sur le comportement alimentaire à l'échelle individuelle, comme des temps de pâturage ou de rumination, pourrait par exemple être couplée aux données de production en vue d'ajuster la quantité de concentrés nécessaire à l'optimisation de la production laitière par animal. Dans le cas d'un robot de traite, les données de géolocalisation devraient aussi permettre de mieux appréhender les visites et temps d'attente en vue d'optimiser l'utilisation de celui-ci.

❖ Amélioration du bien-être et de la santé des animaux

L'outil d'aide à la décision est également un moyen d'assurer un suivi automatique du bien-être et de la santé des animaux à l'échelle individuelle en vue d'avertir l'éleveur des individus nécessitant une attention particulière (Meuret et al., 2013). Dans un contexte où un suivi individuel par l'éleveur ne serait pas possible, l'outil tel qu'il a été envisagé dans ce travail est par conséquent un moyen d'améliorer les performances de l'exploitation en terme de bien-

être animal, l'un des piliers de la transition agroécologique comme en témoigne le projet Ouesterel (LIT OUESTEREL, 2019).

Une détection précoce des évènements de santé comme les boiteries *via* les alertes fournies à l'éleveur favorise une prise en charge rapide permettant généralement de limiter la pénibilité pour les animaux mais aussi les coûts de traitements associés (Willshire and Bell, 2009). De cette manière, l'outil participe à l'amélioration conjointe des performances économiques et relatives à la santé des bovins. Enfin, il devrait permettre de remonter automatiquement des plannings de pâturage de manière fiable contribuant ainsi à une meilleure évaluation du risque d'infestation à *Ostertagia ostertagi* (Chauvin, 2009), et par suite à une utilisation plus raisonnée d'antiparasitaires.

❖ Réduction des impacts environnementaux

Comme expliqué précédemment, l'outil envisagé au cours de ce travail devrait permettre de remonter automatiquement des plannings de pâturage territoriaux avec la pression de pâturage associée. Ces informations pourraient ainsi être mobilisées en vue de réduire et de mieux valoriser les intrants (fermeture du cycle d'azote, plan de fertilisation, etc...) mais également d'adapter les pratiques pour promouvoir la biodiversité.

2.2 Un outil collaboratif qui peut renforcer les liens entre producteur et consommateur dans le cadre d'une vision postmoderne de l'agriculture

❖ Génération de nouvelles connaissances pour mieux intégrer la diversité des territoires

La transition agroécologique nécessite de générer de nombreuses connaissances en vue de limiter les risques pris par les éleveurs (Klerkx et al., 2019; Roger, 2001). En remontant des informations exhaustives sur le comportement couplé à la position des bovins dans la parcelle et ceci de façon continue, l'outil envisagé offre certainement l'opportunité d'enrichir les connaissances sur les besoins et les réactions des animaux en réponse à des conditions spécifiques, inscrites dans un contexte territorial donné. L'outil peut donc être mis au service de la recherche zootechnique afin d'adopter de nouvelles pratiques qui intègrent la diversité des territoires (comportement des animaux selon l'hétérogénéité du couvert, les hauteurs d'herbe, le climat, etc.) (Andriamandroso, 2017; Laca, 2009).

❖ Partage de pratiques entre éleveurs

L'outil envisagé peut également avoir une portée collaborative et participative revendiquée par la vision postmoderne de l'agriculture. En mettant en commun les pratiques et résultats obtenus à l'échelle de l'exploitation et du territoire, cet outil devrait contribuer à la dimension sociale de l'agroécologie.

❖ Renforcement du lien entre producteur et consommateur

L'agroécologie vise à renforcer le lien entre chacun des maillons de la chaîne de production, de l'éleveur au consommateur. Retisser les liens entre élevage et société dans le Nord-Ouest de la France constitue d'ailleurs l'ambition stratégique du projet Ouesterel (LIT OUESTEREL, 2019). A noter que le fossé notable entre consommateurs et acteurs des filières animales s'explique en partie par un manque de dialogue et d'informations. A ce propos, l'outil envisagé au cours de ce travail est un moyen de remonter des informations objectives sur les conditions d'élevage, comme le nombre de jours passés au pâturage par an, le nombre d'heures passées au pâturage par jour, le nombre d'alertes (troubles de santé/inconfort) émises, etc. Ceci correspond d'ailleurs aux démarches du Centre National Interprofessionnel de l'Economie Laitière qui a défini récemment un cahier des charges « lait de pâturage » (journée Association Française pour la Production Fourragère). Certaines entreprises visent également à pouvoir certifier et contrôler des marques avec du pâturage effectif. Ces démarches, appuyées par l'outil d'aide à la décision envisagé, devraient certainement contribuer à rassurer le consommateur sur les produits qu'il consomme, renforçant ainsi le lien avec le producteur.

3. Outil numérique envisagé et agroécologie : quelles contradictions ?

Même si le numérique est sûrement un moyen d'appuyer la transition agroécologique, des contradictions peuvent néanmoins être soulevées entre l'utilisation de l'outil envisagé et le concept même de l'agroécologie. Il convient d'abord de rappeler que la conception, l'utilisation et éventuellement le recyclage des nouvelles technologies ont un coût environnemental en terme de consommation de matières premières et d'énergies non renouvelables (Soulignac et al., 2019). Depuis ses début, l'agroécologie cherche cependant à développer des systèmes de production agricoles exemplaires d'un point de vue environnemental. Une réflexion sur chacune des dimensions du développement durable mérite certainement d'être menée en vue d'évaluer la pertinence du recours aux nouvelles technologies dans le développement de systèmes parcimonieux (Soulignac et al., 2019).

L'agroécologie intègre également la diversité des contextes territoriaux dans le développement des nouveaux systèmes agricoles. Même si l'outil envisagé devrait permettre d'améliorer les connaissances zootechniques en vue de promouvoir la diversité des territoires, son application pour les éleveurs correspondra systématiquement à des détections d'évènements ciblés, calibrés selon une situation spécifique, et fournissant en sortie une alerte uniformisée visant à déclencher une réaction donnée (intervention de l'éleveur, du vétérinaire, de l'inséminateur, etc.). Il semblerait donc que cet outil tende plutôt à uniformiser les pratiques qu'à les diversifier.

La manière dont les alertes seront utilisées suscite également des interrogations. Ainsi, celles-ci peuvent effectivement être perçues comme une aide, visant simplement à accompagner les éleveurs dans leurs décisions mais sans venir remettre en question le fruit de leur réflexion. Ces alertes pourraient aussi être utilisées de façon arbitraire, prenant davantage la forme d'un contrôle plus que d'un soutien, s'écartant alors du concept de l'agroécologie. De plus, ces outils peuvent certainement être profitables à un collectif si les données sont partagées et valorisées à l'échelle d'un territoire mais ils peuvent aussi se restreindre à un usage individuel, cloisonné au sein d'une relation fabricant – conseiller– éleveur. Dans ce dernier cas, l'usage du numérique tendrait plutôt à s'éloigner de l'esprit participatif et collaboratif revendiqué par l'agroécologie. L'usage qui sera fait de ces outils numériques conditionne donc directement leur pertinence dans la transition agroécologique (Klerkx et al., 2019).

D'une manière générale, les nouvelles technologies peuvent certainement offrir des leviers majeurs dans le développement environnemental, économique et social des modèles agricoles, à la fois pour les générations présentes mais également pour les générations futures (Bellon-Maurel and Huyghe, 2019). Néanmoins, le recours au numérique rentre en contradiction avec certains concepts revendiqués par l'agroécologie. Des projets collaboratifs misant sur la synergie entre des acteurs différents aux compétences complémentaires, comme le projet Ouesterel (LIT OUESTEREL, 2019) ou encore #DigitAg, devraient certainement apporter la preuve de la pertinence de la révolution numérique dans la transition agroécologique, mais également d'en exposer les freins et les limites.

Références

- Alexandratos, N., 2012. World Agriculture towards 2030/2050: the 2012 revision 154.
- Alvarenga, F.A.P., Borges, I., Palkovič, L., Rodina, J., Oddy, V.H., Dobos, R.C., 2016. Using a three-axis accelerometer to identify and classify sheep behaviour at pasture. *Appl. Anim. Behav. Sci.* 181, 91–99. <https://doi.org/10.1016/j.applanim.2016.05.026>
- Andriamandroso, A.L.H., 2017. Cattle grazing dynamics under contrasted pasture characteristics at temporal and spatial scales (Sciences agronomiques et ingénierie biologique). Université de Liège, Gembloux Agro-Bio Tech, Liège, Belgique.
- Andriamandroso, A.L.H., Lebeau, F., Beckers, Y., Froidmont, E., Dufrasne, I., Heinesch, B., Dumortier, P., Blanchy, G., Blaise, Y., Bindelle, J., 2017. Development of an open-source algorithm based on inertial measurement units (IMU) of a smartphone to detect cattle grass intake and ruminating behaviors. *Comput. Electron. Agric.* 139, 126–137. <https://doi.org/10.1016/j.compag.2017.05.020>
- Arcidiacono, C., Porto, S.M.C., Mancino, M., Cascone, G., 2017. Development of a threshold-based classifier for real-time recognition of cow feeding and standing behavioural activities from accelerometer data. *Comput. Electron. Agric.* 134, 124–134. <https://doi.org/10.1016/j.compag.2017.01.021>
- Ayumi, V., 2016. Pose-based human action recognition with Extreme Gradient Boosting, in: 2016 IEEE Student Conference on Research and Development (SCORED). Presented at the 2016 IEEE Student Conference on Research and Development (SCORED), IEEE, Kuala Lumpur, pp. 1–5. <https://doi.org/10.1109/SCORED.2016.7810099>
- Babajide Mustapha, I., Saeed, F., 2016. Bioactive Molecule Prediction Using Extreme Gradient Boosting. *Molecules* 21, 983. <https://doi.org/10.3390/molecules21080983>
- Bellon-Maurel, V., Huyghe, C., 2019. Agriculture numérique, une (r)évolution en marche dans les territoires ? - Avant-propos. *Sci. Eaux Territ.*
- Benaissa, S., Tuytens, F.A.M., Plets, D., de Pessemier, T., Trogh, J., Tanghe, E., Martens, L., Vandaele, L., Van Nuffel, A., Joseph, W., Sonck, B., 2017. On the use of on-cow accelerometers for the classification of behaviours in dairy barns. *Res. Vet. Sci.* <https://doi.org/10.1016/j.rvsc.2017.10.005>
- Berckmans, D., 2017. General introduction to precision livestock farming. *Anim. Front.* 7, 6–11. <https://doi.org/10.2527/af.2017.0102>
- Bersch, S., Azzi, D., Khusainov, R., Achumba, I., Ries, J., 2014. Sensor Data Acquisition and Processing Parameters for Human Activity Classification. *Sensors* 14, 4239–4270. <https://doi.org/10.3390/s140304239>
- Chapinal, N., Passillé, A.M. de, Weary D. M., von Keyserlingk A. G., Rushen J., 2009. Using gait score, walking speed, and lying behavior to detect hoof lesions in dairy cows. *J. Dairy Sci.* <https://doi.org/10.3168/jds.2009-2115>
- Chauvin, A., 2009. Le risque parasitaire au pâturage et sa maîtrise 255–264.
- Delagarde, R., Peyraud, J.-L., Wade, M.H., 2010. Daily pattern of feeding activities of dairy cows in a 8-d rotational grazing system. Presented at the 23rd General Meeting of the European Grassland Federation, Kiel, Germany, pp. 931–933.
- Dolecheck, K.A., Heersche, G., Bewley, J.M., 2013. Investment analysis of automated estrus detection technologies. Presented at the Proceedings of the precision dairy conference and expo., University of Minnesota, Mayo Civic Center, Rochester, Minnesota, pp. 103–104.
- Dutta, R., Smith, D., Rawnsley, R., Bishop-Hurley, G., Hills, J., Timms, G., Henry, D., 2015. Dynamic cattle behavioural classification using supervised ensemble classifiers. *Comput. Electron. Agric.* 18–28. <http://dx.doi.org/10.1016/j.compag.2014.12.002>
- FAO, 1996. Sommet mondial de l'alimentation. Rome, Italie.

- Farm Animal Welfare Committee (FAWC) [WWW Document], 2011. URL <https://www.gov.uk/government/groups/farm-animal-welfare-committee-fawc>
- French, P., O'Brien, B., Shalloo, L., 2015. Development and adoption of new technologies to increase the efficiency and sustainability of pasture-based systems. *Anim. Prod. Sci.* 55, 931. <https://doi.org/10.1071/AN14896>
- Hamalainen, W., Jarvinen, M., Martiskainen, P., Mononen, J., 2011. Jerk-based feature extraction for robust activity recognition from acceleration data, in: 2011 11th International Conference on Intelligent Systems Design and Applications. Presented at the 2011 11th International Conference on Intelligent Systems Design and Applications (ISDA), IEEE, Cordoba, Spain, pp. 831–836. <https://doi.org/10.1109/ISDA.2011.6121760>
- High Level Panel of Experts on Food Security and Nutrition, 2019. Agroecological and other innovative approaches for sustainable agriculture and food systems that enhance food security and nutrition, CFS : committee on world food security. Rome, Italy.
- Keogh, E., Chu, S., Hart, D., Pazzani, M., 2001. An online algorithm for segmenting time series, in: Proceedings 2001 IEEE International Conference on Data Mining. Presented at the 2001 IEEE International Conference on Data Mining, IEEE Comput. Soc, San Jose, CA, USA, pp. 289–296. <https://doi.org/10.1109/ICDM.2001.989531>
- Killick, R., Eckley, I.A., 2014. Changepoint : An R Package for Changepoint Analysis. *J. Stat. Softw.* 58. <https://doi.org/10.18637/jss.v058.i03>
- Klerkx, L., Jakku, E., Labarthe, P., 2019. A review of social science on digital agriculture, smart farming and agriculture 4.0: New contributions and a future research agenda. *NJAS - Wagening. J. Life Sci.* 90–91, 100315. <https://doi.org/10.1016/j.njas.2019.100315>
- Laca, E.A., 2009. Precision livestock production: tools and concepts. *Rev. Bras. Zootec.* 38, 123–132. <https://doi.org/10.1590/S1516-35982009001300014>
- LIT OUESTEREL, 2019. Laboratoire d'Innovation Territoriale « Ouest Territoires d'Élevage ».
- Martiskainen, P., Järvinen, M., Skön, J.P., Tiirikainen, J., Kolehmainen, M., Mononen, J., 2009. Cow behaviour pattern recognition using a three-dimensional accelerometer and support vector machines. *Appl. Anim. Behav. Sci.* 119, 32–38.
- Meuret, M., Tichit, M., Hostiou, N., 2013. élevage et pâturage « de précision » : l'animal sous surveillance électronique 12.
- O'Driscoll, K., Lewis, E., Kennedy, E., 2019. Effect of feed allowance at pasture on the lying behaviour of dairy cows. *Appl. Anim. Behav. Sci.* 213, 40–46. <https://doi.org/10.1016/j.applanim.2019.02.002>
- Petiot, C.E., 2019. Étude des liens entre boîtes, comportements et production laitière des vaches au pâturage. ONIRIS - ECOLE NATIONALE VÉTÉRINAIRE, AGROALIMENTAIRE ET DE L'ALIMENTATION, Nantes.
- Rahman, A., Smith, D.V., Little, B., Ingham, A.B., Greenwood, P.L., Bishop-Hurley, G.J., 2018. Cattle behaviour classification from collar, halter, and ear tag sensors. *Inf. Process. Agric.* 5, 124–133. <https://doi.org/10.1016/j.inpa.2017.10.001>
- Riaboff, L., Bedere, N., Couvreur, S., Aubin, S., Goumand, E., Magnier, J., Madouasse, A., Chauvin, A., Plantier, G., 2018. Influence of pasture characteristics and time of day on dairy cow behaviour predicted from GPS-data. *7 Gen. Meet. Eur. Grassl. Fed. EGF* 23, 803–809.
- Ribeiro Filho, H.M.N., Setelich, E.A., Crestani, S., Dias, K.M., Mantovani, C., Valenti, J., 2011. Relationship between diurnal grazing time and herbage intake in dairy cows in rotational grazing. *Ciênc. Rural St. Maria* 41.
- Rigolot, C., 2017. Une approche évolutive des « visions du monde » pour penser les transformations de l'agriculture. *Cah. Agric.* 26, 36001. <https://doi.org/10.1051/cagri/2017015>

- Roger, C., 2001. Agriculture raisonnée, multifonctionnelle, biologique... : quelles voies vers une « agriculture durable » ? INRA Dép. Sci. Soc. Agric. Aliment. Espace Environ. 5p.
- Rushen, J., Chapinal, N., de Passillé, A., 2012. Automated monitoring of behavioural-based animal welfare indicators. *Anim. Welf.* 21, 339–350. <https://doi.org/10.7120/09627286.21.3.339>
- Rutten, C.J., Velthuis, A.G.J., Steeneveld, W., Hogeveen, H., 2013. Sensors to support health management on dairy farms. *J. Dairy Sci.* 1928–1952.
- Sevilla Guzmán, E., 2013. Agroecology and Sustainable Food Systems. *Agroecol. Found. Agrar. Soc. Thought Sociol. Theory* 7, 32–44.
- Shahriar, Md.S., Smith, D., Rahman, A., Freeman, M., Hills, J., Rawnsley, R., Henry, D., Bishop-Hurley, G., 2016. Detecting heat events in dairy cows using accelerometers and unsupervised learning. *Comput. Electron. Agric.* 128, 20–26. <https://doi.org/10.1016/j.compag.2016.08.009>
- Shi, H., Wang, H., Huang, Y., Zhao, L., Qin, C., Liu, C., 2019. A hierarchical method based on weighted extreme gradient boosting in ECG heartbeat classification. *Comput. Methods Programs Biomed.* 171, 1–10. <https://doi.org/10.1016/j.cmpb.2019.02.005>
- Shoaib, M., Scholten, H., Havinga, P.J.M., 2013. Towards Physical Activity Recognition Using Smartphone Sensors, in: 2013 IEEE 10th International Conference on Ubiquitous Intelligence and Computing and 2013 IEEE 10th International Conference on Autonomic and Trusted Computing. Presented at the 2013 IEEE 10th International Conference on Ubiquitous Intelligence & Computing and 2013 IEEE 10th International Conference on Autonomic & Trusted Computing (UIC/ATC), IEEE, Italy, pp. 80–87. <https://doi.org/10.1109/UIC-ATC.2013.43>
- Soullignac, V., Leveau, L., Pinet, F., Bergez, J.-É., 2019. Les technologies de l’information et de la communication dans la transition agroécologique. *Sci. Eaux Territ. Numéro* 29, 34. <https://doi.org/10.3917/set.029.0034>
- Vázquez Diosdado, J.A., Barker, Z.E., Hodges, H.R., Amory, J.R., Croft, D.P., Bell, N.J., Codling, E.A., 2015. Classification of behaviour in housed dairy cows using an accelerometer-based activity monitoring system. *Anim. Biotelemetry* 3. <https://doi.org/10.1186/s40317-015-0045-8>
- Werner, J., Umstatter, C., Kennedy, E., Grant, J., Leso, L., Geoghegan, A., Shalloo, L., Schick, M., O’Brien, B., 2019. Identification of possible cow grazing behaviour indicators for restricted grass availability in a pasture-based spring calving dairy system. *Livest. Sci.* 220, 74–82. <https://doi.org/10.1016/j.livsci.2018.12.004>
- Widowski, T.M., 2001. Shade-Seeking Behavior of Rotationally-Grazed Cows and Calves in a Moderate Climate, in: *Livestock Environment VI, Proceedings of the 6th International Symposium 2001*. Presented at the Livestock Environment VI, Proceedings of the 6th International Symposium 2001, American Society of Agricultural and Biological Engineers. <https://doi.org/10.13031/2013.7126>
- Willshire, J.A., Bell, N.J., 2009. An Economic Review of Cattle Lameness 17, 136–141.
- Yunta, C., Guasch, I., Bach, A., 2012. Short communication: Lying behavior of lactating dairy cows is influenced by lameness especially around feeding time. *J. Dairy Sci.* 95, 6546–6549. <https://doi.org/10.3168/jds.2012-5670>
- Zhao, Y., Lehman, B., Ball, R., Mosesian, J., de Palma, J.-F., 2013. Outlier detection rules for fault detection in solar photovoltaic arrays, in: 2013 Twenty-Eighth Annual IEEE Applied Power Electronics Conference and Exposition (APEC). Presented at the 2013 IEEE Applied Power Electronics Conference and Exposition - APEC 2013, IEEE, Long Beach, CA, USA, pp. 2913–2920. <https://doi.org/10.1109/APEC.2013.6520712>

Conclusion

La transition agroécologique amène à valoriser de nouveau les prairies par le pâturage des bovins laitiers mais la mise en œuvre est particulièrement compliquée, justifiant de développer de nouveaux outils pour accompagner les éleveurs. Bien que l'élevage de précision soit en plein essor, les outils numériques pour le pâturage restent marginaux et leur plus-value pour les éleveurs est souvent mal perçue, justifiant de s'intéresser à leur développement. Pour cela, remonter automatiquement le comportement des vaches laitières au pâturage ainsi que leur position, au moyen d'accéléromètres et GPS, semblait particulièrement pertinent. Afin de lever les deux principaux verrous au développement de ces outils, il convenait de mettre en place un cadre méthodologique pour prédire l'ensemble des comportements des vaches laitières au pâturage et restant fiable quels que soient la période et les animaux équipés.

Le cadre méthodologique développé permet de prédire de manière robuste le comportement d'ingestion au pâturage, de rumination, de repos, de marche et de distinguer les postures « couché » et « debout » à partir de capteurs accélérométriques. Cette méthodologie s'appuie notamment sur (i) des techniques adaptées de traitement de l'accélération brute et sur (ii) une combinaison d'algorithmes qui met en jeu la complémentarité entre des méthodes ensemblistes de *machine learning* et des modèles probabilistes.

Ce travail souligne également le potentiel de la prédiction des comportements des vaches laitières, couplée à la position des animaux, pour relier les comportements aux caractéristiques des prairies et à l'environnement extérieur. Cette approche devrait ainsi permettre de mieux appréhender les changements de comportements relatifs à des conditions de pâturage défavorables au bien-être (stress thermique, stress physique, ressource limitante, etc.).

Des étapes sont encore nécessaires pour aboutir à un outil commercialisable à partir de cette approche. Un volet développement doit être prioritairement mené pour valider le cadre méthodologique sur d'autres animaux. D'autres algorithmes doivent ensuite être mis en place pour assurer la détection automatique des évènements ciblés à partir des comportements remontés. Un travail d'ingénierie est finalement nécessaire pour assurer la praticité et la fonctionnalité de l'outil en vue de garantir son transfert vers le terrain.

Outre les strictes applications proposées dans le cadre de ce travail, l'outil envisagé peut certainement être mis au service la transition agroécologique des élevages de bovins laitiers, quelle que soit l'orientation initiale du modèle de production. Cet outil peut en effet

certainement servir de support à la recherche zootechnique, améliorer le bien-être et la santé des animaux, réduire l'utilisation d'intrants et renforcer le lien entre producteur et consommateur. Utilisé dans une démarche collaborative et participative, ce type d'outil numérique constitue un levier majeur dans le développement environnemental, économique et social des modèles agricoles. Des projets collaboratifs en cours sur l'agroécologie devraient certainement apporter la preuve de la pertinence de la révolution numérique dans cette transition, mais également d'en exposer les freins et les limites.

Références

- Abell, K.M., Theurer, M.E., Larson, R.L., White, B.J., Hardin, D.K., Randle, R.F., 2017. Predicting bull behavior events in a multiple-sire pasture with video analysis, accelerometers, and classification algorithms. *Comput. Electron. Agric.* 136, 221–227. <https://doi.org/10.1016/j.compag.2017.01.030>
- Agabriel, J., Disenhaus, C., Renand, G., Zundel, E., Seegers, H., Faverdin, P., 2011. Elevage bovin et Environnement Quelles solutions techniques ou organisationnelles envisagées par l'INRA ? *Innov. Agron.* 12, 135–156.
- Agreil, C., Meuret, M., 2004. An improved method for quantifying intake rate and ingestive behaviour of ruminants in diverse and variable habitats using direct observation. *Small Rumin. Res.* 54, 99–113.
- Alexandratos, N., 2012. World Agriculture towards 2030/2050: the 2012 revision 154.
- Allain, C., Thomas, G., Chanvallon, A., 2013. Surveillance automatisée des vêlages en élevage bovins laitiers.
- Allain, C., Thomas, G., Chanvallon, A., 2012. Détection automatisée des chaleurs en élevage de bovins laitiers : quel outil choisir ?
- Allen, F.R., Ambikairajah, E., Lovell, N.H., Celler, B.G., 2006. An Adapted Gaussian Mixture Model Approach to Accelerometry-Based Movement Classification Using Time-Domain Features, 4.
- Almeida, P.E., Weber, P.S.D., Burton, J.L., Zanella, A.J., 2008. Depressed DHEA and increased sickness response behaviors in lame dairy cows with inflammatory foot lesions. *Domest. Anim. Endocrinol.* 34, 89–99. <https://doi.org/10.1016/j.domaniend.2006.11.006>
- Alvarenga, F.A.P., Borges, I., Palkovič, L., Rodina, J., Oddy, V.H., Dobos, R.C., 2016. Using a three-axis accelerometer to identify and classify sheep behaviour at pasture. *Appl. Anim. Behav. Sci.* 181, 91–99. <https://doi.org/10.1016/j.applanim.2016.05.026>
- Andriamandroso, A.L.H., 2017a. Cattle grazing dynamics under contrasted pasture characteristics at temporal and spatial scales (Sciences agronomiques et ingénierie biologique). Université de Liège, Gembloux Agro-Bio Tech, Liège, Belgique.
- Andriamandroso, A.L.H., Lebeau, F., Beckers, Y., Froidmont, E., Dufrasne, I., Heinesch, B., Dumortier, P., Blanchy, G., Blaise, Y., Bindelle, J., 2017b. Development of an open-source algorithm based on inertial measurement units (IMU) of a smartphone to detect cattle grass intake and ruminating behaviors. *Comput. Electron. Agric.* 139, 126–137. <https://doi.org/10.1016/j.compag.2017.05.020>
- Arave, C.W., Albright, J.L., 1981. Cattle behaviour. *J. Dairy Sci.* 64, 1318–1329.
- Arcidiacono, C., Porto, S.M.C., Mancino, M., Cascone, G., 2017. Development of a threshold-based classifier for real-time recognition of cow feeding and standing behavioural activities from accelerometer data. *Comput. Electron. Agric.* 134, 124–134. <https://doi.org/10.1016/j.compag.2017.01.021>
- Ayumi, V., 2016. Pose-based human action recognition with Extreme Gradient Boosting, in: 2016 IEEE Student Conference on Research and Development (SCORED). Presented at the 2016 IEEE Student Conference on Research and Development (SCORED), IEEE, Kuala Lumpur, pp. 1–5. <https://doi.org/10.1109/SCORED.2016.7810099>
- Babajide Mustapha, I., Saeed, F., 2016. Bioactive Molecule Prediction Using Extreme Gradient Boosting. *Molecules* 21, 983. <https://doi.org/10.3390/molecules21080983>
- Banos, O., Galvez, J.-M., Damas, M., Pomares, H., Rojas, I., 2014. Window size impact in human activity recognition. *Sensors* 14, 6474–6499. <https://doi.org/10.3390/s140406474>.

- Bao, L., Intille, S.S., 2004. Activity recognition from user-annotated acceleration data. In: Ferscha, A., Mattern, F. (Eds.), *Pervasive Computing*. Springer Berlin Heidelberg, Berlin, Heidelberg, pp. 1–17.
- Barker, Z.E., Vázquez Diosdado, J.A., Codling, E.A., Bell, N.J., Hodges, H.R., Croft, D.P., Amory, J.R., 2018. Use of novel sensors combining local positioning and acceleration to measure feeding behavior differences associated with lameness in dairy cattle. *J.Dairy Sci.* 101, 6310–6321. <https://doi.org/10.3168/jds.2016-12172>.
- Barwick, J., Lamb, D.W., Dobos, R., Welch, M., Trotter, M., 2018. Categorising sheep activity using a tri-axial accelerometer. *Comput. Electron. Agric.* 145, 289–297. <https://doi.org/10.1016/j.compag.2018.01.007>
- Bates, D., Maechler, M., Bolker, B., Walker, S., 2015. Fitting Linear Mixed-Effects Models Using lme4. *J. Stat. Softw.* 67, 1–48. <https://doi.org/10.18637/jss.v067.i01>
- Batista, P.H.D., Almeida, G.L.P.D., Sarmento, R.M., Pandorfi, H., Melo, A.A.S.D., Rolim, M.M., Medeiros, V.W.C.D., Gonçalves, G.E., 2019. Monitoring the bovine activity in grazing by an electronic sensing device based on GPS. *Rev. Ciênc. Agrár.* vol. 42 n.º 2 (2019)-. <https://doi.org/10.19084/rca.17264>
- Barker, Z.E., Vázquez Diosdado, J.A., Codling, E.A., Bell, N.J., Hodges, H.R., Croft, D.P., Amory, J.R., 2018. Use of novel sensors combining local positioning and acceleration to measure feeding behavior differences associated with lameness in dairy cattle. *J. Dairy Sci.* 101, 6310–6321. <https://doi.org/10.3168/jds.2016-12172>
- Bayat, A., Pomplun, M., Tran, D.A., 2014. A study on human activity recognition using accelerometer data from smartphones. *Proc. Comput. Sci.* 34, 450–457. <https://doi.org/10.1016/j.procs.2014.07.009>.
- Bellon Maurel, V., Huyghe, C., 2017. Putting agricultural equipment and digital technologies at the cutting edge of agroecology 7.
- Bellon-Maurel, V., Huyghe, C., 2019. Agriculture numérique, une (r)évolution en marche dans les territoires ? - Avant-propos. *Sci. Eaux Territ.*
- Benaissa, S., Tuytens, F.A.M., Plets, D., Cattrysse, H., Martens, L., Vandaele, L., Joseph, W., Sonck, B., 2018. Classification of ingestive-related cow behaviours using RumiWatch halter and neck-mounted accelerometers. *Appl. Anim. Behav. Sci.* <https://doi.org/10.1016/j.applanim.2018.12.003>
- Benaissa, S., Tuytens, F.A.M., Plets, D., de Pessemier, T., Trogh, J., Tanghe, E., Martens, L., Vandaele, L., Van Nuffel, A., Joseph, W., Sonck, B., 2017. On the use of on-cow accelerometers for the classification of behaviours in dairy barns. *Res. Vet. Sci.* <https://doi.org/10.1016/j.rvsc.2017.10.005>
- Benson, L.C., Clermont, C.A., Osis, S.T., Kobsar, D., Ferber, R., 2018. Classifying running speed conditions using a single wearable sensor: Optimal segmentation and feature extraction methods. *J. Biomech.* 71, 94–99. <https://doi.org/10.1016/j.jbiomech.2018.01.034>
- Béranger, C., Lacombe, P., 2014. La recherche agronomique et la révolution agricole de la seconde moitié du XXe siècle : l'exemple de la prairie. *Histoire de la recherche contemporaine. Rev. Com. Pour L'histoire CNRS* 167-179.
- Béranger, C., Liénard, G., 2006. La Révolution fourragère, 50 ans après. *La Révolution fourragère et les éleveurs. Fourrages* 437-449.
- Béraud, E., Bouhaddi, F., 1996. 25 ans de statistique agricole annuelle – rétrospective 1970 – 1994. *Agreste- Stat. Agric.-Données Chiffrées.*
- Berckmans, D., 2017. General introduction to precision livestock farming. *Anim. Front.* 7, 6–11. <https://doi.org/10.2527/af.2017.0102>
- Berckmans, D., 2014. Precision livestock farming technologies for welfare management in intensive livestock systems. *Rev. Sci. Tech. OIE* 33, 189–196.

- Bernecker, T., Graf, F., Kriegel, H.-P., Moennig, C., Dill, D., Tuermer, C., 2012. Activity recognition on 3d accelerometer data (technical report).
- Bersch, S., Azzi, D., Khusainov, R., Achumba, I., Ries, J., 2014. Sensor Data Acquisition and Processing Parameters for Human Activity Classification. *Sensors* 14, 4239–4270. <https://doi.org/10.3390/s140304239>
- Bivand, R., Keitt, T., Rowlingson, B., 2019. rgdal: Bindings for the “Geospatial” Data Abstraction Library.
- Blackie, N., Bleach, E., Amory, J., Scaife, J., 2011. Impact of lameness on gait characteristics and lying behaviour of zero grazed dairy cattle in early lactation. *Appl. Anim. Behav. Sci.* 129, 67–73. <https://doi.org/10.1016/j.applanim.2010.10.006>
- Borchers, M.R., Chang, Y.M., Tsai, I.C., Wadsworth, B.A., Bewley, J.M., 2016. A validation of technologies monitoring dairy cow feeding, ruminating, and lying behaviors. *J. Dairy Sci.* 99, 7458–7466. <https://doi.org/10.3168/jds.2015-10843>
- Bouten, C.V.C., Koekkoek, K.T.M., Verduin, M., Kodde, R., Janssen, J.D., 1997. A triaxial accelerometer and portable data processing unit for the assessment of daily physical activity. *IEEE Trans. Biomed. Eng.* 44, 136–147. <https://doi.org/10.1109/10.554760>.
- Bramley, R.G.V., 2009. Lessons from nearly 20 years of Precision Agriculture research, development, and adoption as a guide to its appropriate application. *Crop Pasture Sci.* 60, 197. <https://doi.org/10.1071/CP08304>
- Bravo, A. (Ed.), 2009. La société et l'économie à l'aune de la révolution numérique: enjeux et perspectives des prochaines décennies ; (2015 - 2025); rapport de la Commission, Rapports et documents / Centre d'Analyse Stratégique. Documentation Française, Paris.
- Breiman, L., Friedman, J., Olshen, R., Stone, C., 1984. *Classification and Regression Tree*, Wadsworth International. California.
- Breiman, L., 2001. Random Forests. *Mach. Learn.* 45, 5–32.
- Brose, P.W., 1990. Animal training and restraining system. 4,898,120.
- Brown, D.D., Kays, R., Wikelski, M., Wilson, R., Klimley, A.P., 2013. Observing the unwatchable through acceleration logging of animal behavior. *Anim. Biotelemetry* 16p.
- Burges, C.J.C., 1998. A tutorial on support vector machines for pattern recognition. *Data Min. Knowl. Discov.* 2, 121–167
- Burow, E., Rousing, T., Thomsen, P.T., Otten, N.D., Sorensen, J.T., 2013. Effect of grazing on the cow welfare of dairy herds evaluated by a multidimensional welfare index. *Animal* 7, 834–842. <https://doi.org/10.1017/S1751731112002297>.
- Cardoso, C.S., Hötzel, M.J., Weary, D.M., Robbins, J.A., von Keyserlingk, M.A.G., 2016. Imagining the ideal dairy farm. *J. Dairy Sci.* 99, 1663–1671. <https://doi.org/10.3168/jds.2015-9925>
- Carpentier, B., Cabon, G., 2011. Le maïs fourrage : élaboration du rendement et de la qualité, récolte et conservation. *Fourrages* 11–23.
- Carvalho, P.C.F., 2013. Harry Stobbs memorial lecture: can grazing behavior support innovations in grassland management? *Trop. Grassl.* 1, 137–155.
- Chanvallon, A., Gatien, J., Lamy, J.M., Philipot, J.M., Girardot, J., Davière, J.B., Ribaud, D., Salvetti, P., 2012a. Evaluation automatisée des chaleurs par différents appareils chez la vache laitière. Presented at the Rencontre Recherche Ruminants.
- Chanvallon, A., Leblay, A., Girardot, J., Davière, J.B., Ribaud, D., Allain, C., Lamy, J.M., 2012b. Surveillance automatisée des vèlages chez la vache laitière.
- Chapinal, N., Passillé, A.M. de, Weary D. M., von Keyserlingk A. G., Rushen J., 2009. Using gait score, walking speed, and lying behavior to detect hoof lesions in dairy cows. *J. Dairy Sci.* <https://doi.org/10.3168/jds.2009-2115>
- Chauhan, N., 2019. Decision Tree Algorithm — Explained [WWW Document]. *Data Sci.* URL <https://towardsdatascience.com/decision-tree-algorithm-explained-83beb6e78ef4>

- Chauvin, A., 2009. Le risque parasitaire au pâturage et sa maîtrise 255–264.
- Chauvin, A., Vermesse, R., Lardoux, S., Masson, M., 2008. Parasit'Info : un système expert d'aide à la gestion du risque d'helminthoses en élevage bovin. Presented at the Rencontre Recherche Ruminants.
- Chen, T., He, T., Benesty, M., Khotilovich, V., Tang, Y., Cho, H., Chen, K., Mitchell, R., Cano, I., Zhou, T., Li, M., Xie, J., Lin, M., Geng, Y., Li, Y., 2018. xgboost: Extreme Gradient Boosting.
- Chénais, F., Seuret, J.M., Brunshwig, P., Fiorelli, J.L., 2001. Pour un rôle croissant du pâturage dans les systèmes bovins laitiers 17.
- Chilliard, Y., Bauchart, D., Lessire, M., Schmidely, P., Mourot, J., Champanelle, S.-G., 2008. Qualité des produits : modulation par l'alimentation des animaux de la composition en acides gras du lait et de la viande 12.
- Claveirole, C., 2016. La transition agroécologique : défis et enjeux (No. CESL1100013X). Conseil économique, social et environnemental.
- Cohen, J., 1960. A Coefficient of Agreement for Nominal Scales. *Educ. Psychol. Meas.* 20, 37–46. <https://doi.org/10.1177/001316446002000104>
- Cornuéjols, A., 2019. L'apprentissage de modèles de Markov cachés. Master Informatique et Systèmes Intelligents- AgroParisTech, Paris, France.
- Coulon, J.-B., Delacroix-Buchet, A., Martin, B., Pirisi, A., 2005. Facteurs de production et qualité sensorielle des fromages. *Prod. Anim.* 1, 49–62.
- Couvreur, S., Delaby, L., Doligez, E., Mahmoudi, P., Marnay, L., Michaud, A., Navelet, C., Paulin, S., Plantureux, S., Puthod, R., 2018. Les prairies au service de l'élevage. Comprendre, gérer et valoriser les prairies., Educagri éditions. ed. Dijon.
- de Schutter, O., 2010. Rapport: agroécologie et droit à l'alimentation (No. GE.10-17850). Organisation des Nations Unies, Genève.
- Dawkins, M.S., 2017. Animal welfare and efficient farming: is conflict inevitable? *Anim. Prod. Sci.* 57, 201. <https://doi.org/10.1071/AN15383>
- Decandia, M., Giovanetti, V., Molle, G., Acciaro, M., Mameli, M., Cabiddu, A., Cossu, R., Serra, M.G., Manca, C., Rassu, S.P.G., Dimauro, C., 2018. The effect of different time epoch settings on the classification of sheep behaviour using tri-axial accelerometry. *Comput. Electron. Agric.* 154, 112–119. <https://doi.org/10.1016/j.compag.2018.09.002>
- Delaby, L., Peyraud, J.L., Favardin, P., 2001. Pâtur' IN : le pâturage des vaches laitières assisté par ordinateur. *Fourrages* 385–398.
- Delagarde, R., Caudal, J.-P., Peyraud, J.-L., 1999. Development of an automatic bitemeter for grazing cattle. *Ann. Zootech.* 48, 329–339. <https://doi.org/10.1051/animres:19990501>
- Delagarde, R., Peyraud, J.-L., Wade, M.H., 2010. Daily pattern of feeding activities of dairy cows in a 8-d rotational grazing system. Presented at the 23rd General Meeting of the European Grassland Federation, Kiel, Germany, pp. 931–933.
- Delanoue, E., Roguet, C., 2015. Acceptabilité sociale de l'élevage en France : recensement et analyse des principales controverses à partir des regards croisés de différents acteurs 12.
- Desriers, M., 2007. L'agriculture française depuis cinquante ans : des petites exploitations familiales aux droits à paiement unique. Référence, INSEE (Eds) 7-30.
- De Vries, D.M. (viaf)290898456, de Boer, Th.A., 1959. Methods used in botanical grassland research in the Netherlands and their application. Publ. 1959 Wagening. Inst. Voor Biol. En Scheikd. Onderz. Van Landbouwgewassen.
- DeVries, T.J., Beauchemin, K.A., Dohme, F., Schwartzkopf-Genswein, K.S., 2009. Repeated ruminal acidosis challenges in lactating dairy cows at high and low risk for developing acidosis: Feeding, ruminating, and lying behavior. *J. Dairy Sci.* 92, 5067–5078. <https://doi.org/10.3168/jds.2009-2102>

- Dieulot, R., 2013. Résultats de l'observatoire technicoéconomique du RAD. Exerc. Comptab. 2013 16.
- Dillon, P., 2011. The dairy industry: planning for 2020. Presented at the Proceedings of the Teagasc national dairy conference, Cork and Athlone, pp. 1–25.
- Dockes, A.C., Kling-Eveillard, F., Jacquinet, M., Beche, J.M., 2007. Consommateurs et éleveurs de bovins face à la problématique du bien-être animal. Presented at the Rencontre, Recherche, Ruminants, pp. 285–292.
- Dolecheck, K.A., Heersche, G., Bewley, J.M., 2013. Investment analysis of automated estrus detection technologies. Presented at the Proceedings of the precision dairy conference and expo., University of Minnesota, Mayo Civic Center, Rochester, Minnesota, pp. 103–104.
- Dutta, R., Smith, D., Rawnsley, R., Bishop-Hurley, G., Hills, J., Timms, G., Henry, D., 2015. Dynamic cattle behavioural classification using supervised ensemble classifiers. Comput. Electron. Agric. 18–28. <http://dx.doi.org/10.1016/j.compag.2014.12.002>
- Erdaş, Ç.B., Atasoy, I., Açııcı, K., Oğul, H., 2016. Integrating Features for Accelerometer-based Activity Recognition. Procedia Comput. Sci. 98, 522–527. <https://doi.org/10.1016/j.procs.2016.09.070>
- Fabien, M., 2019. Boosting and AdaBoost clearly explained [WWW Document]. Data Sci. URL <https://towardsdatascience.com/boosting-and-adaboost-clearly-explained-856e21152d3e>
- FAO, 1996. Sommet mondial de l'alimentation. Rome, Italie.
- Farm Animal Welfare Committee (FAWC) [WWW Document], 2011. URL <https://www.gov.uk/government/groups/farm-animal-welfare-committee-fawc>
- Fida, B., Bernabucci, I., Bibbo, D., Conforto, S., Schmid, M., 2015. Pre-Processing Effect on the Accuracy of Event-Based Activity Segmentation and Classification through Inertial Sensors. Sensors 15, 23095–23109. <https://doi.org/10.3390/s150923095>
- Figo, D., Diniz, P.C., Ferreira, D.R., Cardoso, J.M.P., 2010. Preprocessing techniques for context recognition from accelerometer data. Pers. Ubiquitous Comput. 14, 645–662. <https://doi.org/10.1007/s00779-010-0293-9>.
- Fox, J., Weisberg, S., 2011. An R Companion to Applied Regression, second ed. Sage, Thousand Oaks CA.
- Forney, G.D., 1973. The Viterbi algorithm. Proc. IEEE 61, 268–278.
- FranceAgriMer, 2019. Consommation de produits laitiers en 2018.
- French, P., O'Brien, B., Shalloo, L., 2015. Development and adoption of new technologies to increase the efficiency and sustainability of pasture-based systems. Anim. Prod. Sci. 55, 931. <https://doi.org/10.1071/AN14896>
- Friedman, J.H., 2001. Greedy function approximation: a gradient boosting machine. Ann. Stat. 29, 1189–1232.
- Friggens, N., Bjerring, M., Ridder, C., Hjsgaard, S., Larsen, T., 2008. Improved Detection of Reproductive Status in Dairy Cows Using Milk Progesterone Measurements. Reprod. Domest. Anim. 43, 113–121. <https://doi.org/10.1111/j.1439-0531.2008.01150.x>
- Fulkerson, W.J., McKean, K., Nandra, K.S., Barchia, I.M., 2005. Benefits of accurately allocating feed on a daily basis to dairy cows grazing pasture. Aust. J. Exp. Agric. 45, 331. <https://doi.org/10.1071/EA03109>.
- Gac, A., Dollé, J.-B., Le Gall, A., Klumpp, K., Tallec, T., Mousset, J., Eglin, T., Bispo, A., Peyraud, J.L., Faverdin, P., 2010. Le stockage de Carbone par les prairies : Une voie d'atténuation de l'impact de l'élevage herbivore sur l'effet de serre.
- Galindo, F., Broom, D.M., 2002. The Effects of Lameness on Social and Individual Behavior of Dairy Cows. J. Appl. Anim. Welf. Sci. 5, 193–201. https://doi.org/10.1207/S15327604JAWS0503_03

- Ganskopp, D.C., Johnson, D.D., 2007. GPS Error in Studies Addressing Animal Movements and Activities. *Rangel. Ecol. Manag.* 60, 350–358.
- Géoportail [WWW Document], 2006. Portail Natl. Connaiss. Territ. Mis En Oeuvre Par IGN. URL <https://www.geoportail.gouv.fr/>
- Gibb, M.J., Huckle, C.A., Nuthall, R., Rook, A.J., 1999. The effect of physiological state lactating or dry/ and sward surface height on grazing behaviour and intake by dairy cows. *Appl. Anim. Behav. Sci.* 63, 269–287.
- Giovanetti, V., Decandia, M., Molle, G., Acciaro, M., Mameli, M., Cabiddu, A., Cossu, R., Serra, M.G., Manca, C., Rassu, S.P.G., Dimauro, C., 2017. Automatic classification system for grazing, ruminating and resting behaviour of dairy sheep using a tri-axial accelerometer. *Livest. Sci.* 196, 42–48. <https://doi.org/10.1016/j.livsci.2016.12.011>
- Gliessman, S., 2018. Defining Agroecology. *Agroecol. Sustain. Food Syst.* 42, 599–600. <https://doi.org/10.1080/21683565.2018.1432329>
- Gliessman, S., 2007. *Agroecology: The Ecology of Sustainable Food Systems*, 2nd edition. ed. CRC Press.
- Gonzalez, L.A., Bishop-Hurley, G.J., Handcock, R.N., Crossman, C., 2015. Behavioral classification of data from collars containing motion sensors in grazing cattle. *Comput. Electron. Agric.* 91–102. <http://dx.doi.org/10.1016/j.compag.2014.10.018>
- Gräler, B., Pebesma, E., Heuvelink, G., 2016. Spatio-Temporal Interpolation using gstat. *R J.* 8, 204–218.
- Hamalainen, W., Jarvinen, M., Martiskainen, P., Mononen, J., 2011. Jerk-based feature extraction for robust activity recognition from acceleration data, in: 2011 11th International Conference on Intelligent Systems Design and Applications. Presented at the 2011 11th International Conference on Intelligent Systems Design and Applications (ISDA), IEEE, Cordoba, Spain, pp. 831–836. <https://doi.org/10.1109/ISDA.2011.6121760>
- Hamäläinen, W., Järvinen, M., Martiskainen, P., Mononen, J., 2011. Jerk-based feature extraction for robust activity recognition from acceleration data, in: *Intelligent Systems Design and Applications (ISDA)*, 2011 11th International Conference On. IEEE, pp. 831–836.
- Hastie, T., Tibshirani, R., Friedman, J., 2011. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, Springer Series in Statistics.
- High Level Panel of Experts on Food Security and Nutrition, 2019. *Agroecological and other innovative approaches for sustainable agriculture and food systems that enhance food security and nutrition*, CFS : committee on world food security. Rome, Italy.
- Hills, J.L., Rawnsley, R., Harrison, M.T., Bishop-Hurley, G.J., Henry, D.A., Raedts, P., Freeman, M., Roche, J.R., 2016. Precision feeding and grazing management for temperate pasture-based dairy systems. *Precis. Dairy Farming*.
- Hijmans, R.J., 2019. *raster: Geographic Data Analysis and Modeling*.
- Himmelman, L., 2010. *HMM: HMM – Hidden Markov Models*.
- Hofstetter, P., Frey, H.-J., Gazzarin, C., Wyss, U., Kunz, P., 2014. Dairy farming: indoor v. pasture-based feeding. *J. Agric. Sci.* 152, 994–1011. <https://doi.org/10.1017/S0021859614000227>
- Hokkanen, A.-H., Hänninen, L., Tiusanen, J., Pastell, M., 2011. Predicting sleep and lying time of calves with a support vector machine classifier using accelerometer data. *Appl. Anim. Behav. Sci.* 134, 10–15. <https://doi.org/10.1016/j.applanim.2011.06.016>
- Huyghe, C., 2009. La multifonctionnalité des prairies en France II. Conciliation des fonctions de production et de préservation de l’environnement. *Cah. Agric.* 18, 7–16. <https://doi.org/10.1684/agr.2009.0263>

- Kamminga, J.W., Le, D.V., Meijers, J.P., Bisby, H., Meratnia, N., Havinga, P.J.M., 2018. Robust Sensor-Orientation-Independent Feature Selection for Animal Activity Recognition on Collar Tags. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.* 2, 1–27. <https://doi.org/10.1145/3191747>
- Kamphuis, C., DelaRue, B., Burke, C.R., Jago, J., 2012. Field evaluation of 2 collar-mounted activity meters for detecting cows in estrus on a large pasture-grazed dairy farm. *J. Dairy Sci.* 95, 3045–3056. <https://doi.org/10.3168/jds.2011-4934>.
- Karantonis, D.M., Narayanan, M.R., Mathie, M., Lovell, N.H., Celler, B.G., 2006. Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring. *IEEE Trans. Inf. Technol. Biomed.* 10, 156–167. <https://doi.org/10.1109/TITB.2005.856864>
- Karatzoglou, A., Smola, A., Hornik, K., Zeileis, A., 2004. kernlab – An S4 Package for Kernel Methods in R. *J. Stat. Softw.* 11, 1–20. <https://doi.org/10.18637/jss.v011.i09>.
- Kasfi, K.T., Hellicar, A., Rahman, A., 2016. Convolutional neural network for time series cattle behaviour classification. In: Hellicar, Andrew, Rahman, Ashfaque, Koch, Fernando (Eds.), *Proceedings of the Workshop on Time Series Analytics and Applications (TSAA '16)*. ACM, New York, NY, USA, pp. 8–12.
- Kennedy, E., Curran, J., Mayes, B., McEvoy, M., Murphy, J.P., O'Donovan, M., 2011. Restricting dairy cow access time to pasture in early lactation: the effects on milk production, grazing behaviour and dry matter intake. *Animal* 1805–1813. <https://doi.org/10.1017/S1751731111000826>
- Kennedy, E., McEvoy, M., Murphy, J.P., O'Donovan, M., 2009. Effect of restricted access time to pasture on dairy cow milk production, grazing behavior, and dry matter intake. *J. Dairy Sci.* 92, 168–176. <https://doi.org/10.3168/jds.2008-1091>
- Keogh, E., Chu, S., Hart, D., Pazzani, M., 2001. An online algorithm for segmenting time series, in: *Proceedings 2001 IEEE International Conference on Data Mining*. Presented at the 2001 IEEE International Conference on Data Mining, IEEE Comput. Soc, San Jose, CA, USA, pp. 289–296. <https://doi.org/10.1109/ICDM.2001.989531>
- Killick, R., Eckley, I.A., 2014. Changepoint : An R Package for Changepoint Analysis. *J. Stat. Softw.* 58. <https://doi.org/10.18637/jss.v058.i03>
- Klerkx, L., Jakku, E., Labarthe, P., 2019. A review of social science on digital agriculture, smart farming and agriculture 4.0: New contributions and a future research agenda. *NJAS - Wageningen. J. Life Sci.* 90–91, 100315. <https://doi.org/10.1016/j.njas.2019.100315>
- Kozina, S., Lus̆trek, M., Gams, M., 2011. Dynamic signal segmentation for activity recognition, in: *Proceedings of International Joint Conference on Artificial Intelligence*. Presented at the International Joint Conference on Artificial Intelligence, Barcelona, Spain, pp. 15–22.
- Kuhn, M., Wing, J., Weston, S., Williams, A., Keefer, C., Engelhardt, A., Cooper, T., Mayer, Z., Kenkel, B., Benesty, M., Lescarbeau, R., Ziem, A., Scrucca, L., Tang, Y., Candan, C. and Hunt, T., 2018. caret: Classification and Regression Training. R package version 6.0-81. <https://CRAN.R-project.org/package=caret>
- La France Agricole. La tétanie d'herbage [WWW Document], 2005. . Fr. Agric. URL <http://www.lafranceagricole.fr/article/la-tetanie-d-herbage-1,0,42532991.html>
- Laca, E.A., 2009. Precision livestock production: tools and concepts. *Rev. Bras. Zootec.* 38, 123–132. <https://doi.org/10.1590/S1516-35982009001300014>
- Larson-Praplan, S., George, M.R., Buckhouse, J.C., Laca, E.A., 2015. Spatial and temporal domains of scale of grazing cattle. *Anim. Prod. Sci.* <http://dx.doi.org/10.1071/AN14641>
- Le, S., Fosse, J., Husson, F., 2008. FactoMineR: An R Package for Multivariate Analysis. *J. Stat. Softw.* 25, 1–18. <https://doi.org/10.18637/jss.v025.i01>

- Lee, K., Kwan, M.-P., 2018. Physical activity classification in free-living conditions using smartphone accelerometer data and exploration of predicted results. *Comput. Environ. Urban Syst.* 67, 124–131. <https://doi.org/10.1016/j.compenvurbsys.2017.09.012>.
- Le Gall, A., Faverdin, P., Thomet, P., Verité, R., 2001. Le pâturage en Nouvelle-Zélande : des idées pour les régions arrosées d'Europe 21.
- Lenth, R.V., 2016. Least-squares means: the R package lsmeans. *J. Statist. Software* 69 (1), 1–33. <https://doi.org/10.18637/jss.v069.i01>.
- Le Roux, X., 2008. Agriculture et biodiversité. Valoriser les synergies. *Expert. Sci. Collect.* 117.
- Leray, O., Doligez, P., Jost, J., Pottier, E., Delaby, L., 2017. Présentation des différentes techniques de pâturage selon les espèces herbivores utilisatrices 7.
- Liaw, A., Wiener, M., 2002. Classification and Regression by randomForest. *R News* 2, 18–22. <https://CRAN.R-project.org/doc/Rnews/>.
- LIT OUESTEREL, 2019. Laboratoire d'Innovation Territoriale « Ouest Territoires d'Élevage ».
- Lush, L., Wilson, R.P., Holton, M.D., Hopkins, P., Marsden, K.A., Chadwick, D.R., King, A.J., 2018. Classification of sheep urination events using accelerometers to aid improved measurements of livestock contributions to nitrous oxide emissions. *Comput. Electron. Agric.* 150, 170–177. <https://doi.org/10.1016/j.compag.2018.04.018>
- Manning, J., Cronin, G., González, L., Hall, E., Merchant, A., Ingram, L., 2017. The Behavioural Responses of Beef Cattle (*Bos taurus*) to Declining Pasture Availability and the Use of GNSS Technology to Determine Grazing Preference. *Agriculture* 7, 45. <https://doi.org/10.3390/agriculture7050045>
- Marais, J., Roux, S.P.L., Wolhuter, R., Niesler, T., 2014. Automatic classification of sheep behaviour using 3-axis accelerometer data, 6.
- Marsh, R.E., 1999. Fenceless animal control system using GPS location information. 5,868,100,.
- Martiskainen, P., Järvinen, M., Skön, J.P., Tiirikainen, J., Kolehmainen, M., Mononen, J., 2009. Cow behaviour pattern recognition using a three-dimensional accelerometer and support vector machines. *Appl. Anim. Behav. Sci.* 119, 32–38.
- Mathie, M.J., Coster, A.C.F., Lovell, N.H., Celler, B.G., 2004. Accelerometry: providing an integrated, practical method for long-term, ambulatory monitoring of human movement. *Physiol. Meas.* 25, R1–R20. <https://doi.org/10.1088/0967-3334/25/2/R01>.
- Mattachini, G., Riva, E., Perazzolo, F., Naldi, E., Provolo, G., 2016. Monitoring feeding behaviour of dairy cows using accelerometers. *J. Agric. Eng.* 47, 54. <https://doi.org/10.4081/jae.2016.498>
- Maurer, U., Smailagic, A., Siewiorek, D.P., Deisher, M., 2006. Activity recognition and monitoring using multiple sensors on different body positions. In: *International on Wearable and Implantable Body Sensor Networks (BSN'06)*. Presented at the International Workshop on Wearable and Implantable Body Sensor Networks (BSN'06). IEEE, Cambridge, MA, USA, pp. 113–116.
- McSweeney, D., Foley, C., Halton, P., O'Brien, B., 2015. Calibration of an automated grass measurement tool to enhance the precision of grass measurement in pasture based farming systems. Presented at the Teagasc Ag conference, Tullamore.
- Meuret, M., Tichit, M., Hostiou, N., 2013. élevage et pâturage « de précision » : l'animal sous surveillance électronique 12.
- Météo France, 2019. Météo France - données publiques [WWW Document]. URL <https://donneespubliques.meteofrance.fr/>
- Milone, D.H., Galli, J.R., Cangiano, C.A., Rufiner, H.L., Laca, E.A., 2012. Automatic recognition of ingestive sounds of cattle based on hidden Markov models. *Comput. Electron. Agric.* 87, 51–55. <https://doi.org/10.1016/j.compag.2012.05.004>

- Moreau, M., Siebert, S., Buerkert, A., Schlecht, E., 2009. Use of a tri-axial accelerometer for automated recording and classification of goats' grazing behaviour. *Appl. Anim. Behav. Sci.* 119, 158–170. <https://doi.org/10.1016/j.applanim.2009.04.008>
- Munksgaard, L., Simonsen, H.B., 1996. Behavioral and pituitary adrenal-axis responses of dairy cows to social isolation and deprivation of lying down. *J. Anim. Sci.* 74, 769. <https://doi.org/10.2527/1996.744769x>
- Müller, R., Schrader, L., 2003. A new method to measure behavioural activity levels in dairy cows. *Appl. Anim. Behav. Sci.* 83, 247–258. [https://doi.org/10.1016/S0168-1591\(03\)00141-2](https://doi.org/10.1016/S0168-1591(03)00141-2)
- Nadimi, E.S., Sjøgaard, H.T., Bak, T., 2008. ZigBee-based wireless sensor networks for classifying the behaviour of a herd of animals using classification trees. *Biosyst. Eng.* 100, 167–176. <https://doi.org/10.1016/j.biosystemseng.2008.03.003>
- Nadin, L.B., Chopra, F.S., Gibb, M.J., Trindade, J.K. da, Amaral, G.A. do, de Faccio Carvalho, P.C., Gonda, H.L., 2012. Comparison of methods to quantify the number of bites in calves grazing winter oats with different sward heights. *Appl. Anim. Behav. Sci.* 139, 50–57. <https://doi.org/10.1016/j.applanim.2012.03.001>
- Nathan, R., Spiegel, O., Fortmann-Roe, S., Harel, R., Wikelski, M., Getz, W.M., 2012. Using tri-axial acceleration data to identify behavioral modes of free-ranging animals: general concepts and tools illustrated for griffon vultures. *J. Exp. Biol.* 986–996. <https://doi.org/10.1242/jeb.058602>
- Navon, S., Mizrach, A., Hetzroni, A., Ungar, E.D., 2013. Automatic recognition of jaw movements in free-ranging cattle, goats and sheep, using acoustic monitoring. *Biosyst. Eng.* 114, 474–483. <https://doi.org/10.1016/j.biosystemseng.2012.08.005>
- Nitsch, H., Osterburg, B., Roggendorf, W., Laggner, B., 2012. Cross compliance and the protection of grassland – Illustrative analyses of land use transitions between permanent grassland and arable land in German regions. *Land Use Policy* 29, 440–448. <https://doi.org/10.1016/j.landusepol.2011.09.001>
- Noor, M.H.M., Salcic, Z., Wang, K.I.-K., 2017. Adaptive sliding window segmentation for physical activity recognition using a single tri-axial accelerometer. *Pervasive Mob. Comput.* 38, 41–59. <https://doi.org/10.1016/j.pmcj.2016.09.009>
- Norring, M., Haggman, J., Simojoki, H., Tamminen, P., Winckler, C., Pastell, M., 2014. Short communication: Lameness impairs feeding behavior of dairy cows. *J. Dairy Sci.* 97, 4317–4321. <https://doi.org/10.3168/jds.2013-7512>
- O'Brien, D., Shalloo, L., Patton, J., Buckley, F., Grainger, C., Wallace, M., 2012. A life cycle assessment of seasonal grass-based and confinement dairy farms. *Agric. Syst.* 107, 33–46. <https://doi.org/10.1016/j.agsy.2011.11.004>
- O'Connor, A.H., Bokkers, E.A.M., de Boer, I.J.M., Hogeveen, H., Sayers, R., Byrne, N., Ruelle, E., Shalloo, L., 2019. Associating cow characteristics with mobility scores in pasture-based dairy cows. *J. Dairy Sci.* 102, 8332–8342. <https://doi.org/10.3168/jds.2018-15719>
- O'Driscoll, K., Lewis, E., Kennedy, E., 2019. Effect of feed allowance at pasture on the lying behaviour of dairy cows. *Appl. Anim. Behav. Sci.* 213, 40–46. <https://doi.org/10.1016/j.applanim.2019.02.002>
- O'Donnell, T.G., Walton, G.A., 1969. Some observations on the behaviour and hill-pasture utilization of irish cattle. *Grass Forage Sci.* 24, 128–133. <https://doi.org/10.1111/j.1365-2494.1969.tb01057.x>
- O'Mara, F.P., 2012. The role of grasslands in food security and climate change. *Ann. Bot.* 110, 1263–1270. <https://doi.org/10.1093/aob/mcs209>
- Oshima, Y., Kawaguchi, K., Tanaka, S., Ohkawara, K., Hikihara, Y., Ishikawa-Takata, K., Tabata, I., 2010. Classifying household and locomotive activities using a triaxial

- accelerometer. *Gait Posture* 31, 370–374. <https://doi.org/10.1016/j.gaitpost.2010.01.005>.
- Peach, D., Van Hoomissen, J., Callender, H.L., 2014. Exploring the ActiLife® filtration algorithm: converting raw acceleration data to counts. *Physiol. Meas.* 35, 2359–2367. <https://doi.org/10.1088/0967-3334/35/12/2359>.
- Pebesma, E.J., Bivan, R.S., 2005. Classes and methods for spatial data in R.
- Penning, P.D., 1983. A technique to record automatically some aspects of grazing and ruminating behaviour in sheep. *Grass Forage Sci.* 38, 89–96. <https://doi.org/10.1111/j.1365-2494.1983.tb01626.x>
- Petiot, C.E., 2019. Étude des liens entre boîtes, comportements et production laitière des vaches au pâturage. ONIRIS - ECOLE NATIONALE VÉTÉRINAIRE, AGROALIMENTAIRE ET DE L'ALIMENTATION, Nantes.
- Phillips, C.J.C., Rind, M.I., 2002. The Effects of Social Dominance on the Production and Behavior of Grazing Dairy Cows Offered Forage Supplements. *J. Dairy Sci.* 85, 51–59. [https://doi.org/10.3168/jds.S0022-0302\(02\)74052-6](https://doi.org/10.3168/jds.S0022-0302(02)74052-6)
- Pober, D.M., Staudenmayer, J., Raphael, C., Freedson, P.S., 2006. Development of novel techniques to classify physical activity mode using accelerometers: Med. Sci. Assessing machine learning classifiers for the detection of animals' behavior using depth-based tracking. *Expert Syst. Appl.* 86, 235–246. <https://doi.org/10.1016/j.eswa.2017.05.063>.
- Pons, P., Jaen, J., Catala, A., 2017. Assessing machine learning classifiers for the detection of animals' behavior using depth-based tracking. *Expert Syst. Appl.* 86, 235–246. <https://doi.org/10.1016/j.eswa.2017.05.063>.
- Pflimlin, A., Faverdin, P., Béranger, C., 2009. Un demi-siècle d'évolution de l'élevage bovin. Bilan et perspectives 36.
- Pflimlin, A., Hubert, B., Leaver, D., 2001. Pâturage : importance actuelle et nouveaux enjeux 13.
- Pietka, E., 1988. Expert systems in parameter extraction of the ECG signal, in: In Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Presented at the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, New Orleans, LA, USA, pp. 165–166.
- Preece, S.J., Goulermas, J.Y., Kenney, L.P.J., Howard, D., 2009. A comparison of feature extraction methods for the classification of dynamic activities from accelerometer data. *IEEE Trans. Biomed. Eng.* 56, 871–879. <https://doi.org/10.1109/TBME.2008.2006190>.
- Putfarken, D., Dengler, J., Lehmann, S., Härdtle, W., 2008. Site use of grazing cattle and sheep in a large-scale pasture landscape: A GPS/GIS assessment. *Appl. Anim. Behav. Sci.* 111, 54–67. <https://doi.org/10.1016/j.applanim.2007.05.012>
- Quante, M., Kaplan, E.R., Rueschman, M., Cailier, M., Buxton, O.M., Redline, S., 2015. Practical considerations in using accelerometers to assess physical activity, sedentary behavior, and sleep. *Sleep Health* 1, 275–284. <https://doi.org/10.1016/j.sleh.2015.09.002>
- Rahman, A., Smith, D., Hills, J., Bishop-Hurley, G., Henry, D., Rawnsley, R., 2016. A comparison of autoencoder and statistical features for cattle behaviour classification. In: Presented at the International Joint Conference on Neural Networks (IJCNN). Vancouver, BC, pp. 2954–2960.
- Rahman, A., Smith, D.V., Little, B., Ingham, A.B., Greenwood, P.L., Bishop-Hurley, G.J., 2018. Cattle behaviour classification from collar, halter, and ear tag sensors. *Inf. Process. Agric.* 5, 124–133. <https://doi.org/10.1016/j.inpa.2017.10.001>
- R Core Team, 2019. R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria

- Ranjbar, S., Rabiee, A.R., Gunn, A., House, J.K., 2016. Identifying risk factors associated with lameness in pasture-based dairy herds. *J. Dairy Sci.* 99, 7495–7505. <https://doi.org/10.3168/jds.2016-11142>
- Riaboff, L., Bedere, N., Couvreur, S., Aubin, S., Goumand, E., Magnier, J., Madouasse, A., Chauvin, A., Plantier, G., 2018. Influence of pasture characteristics and time of day on dairy cow behaviour predicted from GPS-data. *7 Gen. Meet. Eur. Grassl. Fed. EGF 23*, 803–809.
- Riaboff, L., Aubin, S., Bedere, N., Couvreur, S., Madouasse, A., Goumand, E., Chauvin, A., Plantier, G., 2019. Evaluation of pre-processing methods for the prediction of cattle behaviour from accelerometer data. *Comput. Electron. Agric.* 165, 104961. <https://doi.org/10.1016/j.compag.2019.104961>
- Riaboff, L., Poggi, S., Madouasse, A., Couvreur, S., Aubin, S., Bédère, N., Goumand, E., Chauvin, A., Plantier, G., 2020. Development of a methodological framework for a robust prediction of the main behaviours of dairy cows using a combination of machine learning algorithms on accelerometer data. *Comput. Electron. Agric.* 169, 105179. <https://doi.org/10.1016/j.compag.2019.105179>
- Ribeiro Filho, H.M.N., Setelich, E.A., Crestani, S., Dias, K.M., Mantovani, C., Valenti, J., 2011. Relationship between diurnal grazing time and herbage intake in dairy cows in rotational grazing. *Ciênc. Rural St. Maria* 41.
- Rigolot, C., 2017. Une approche évolutive des « visions du monde » pour penser les transformations de l’agriculture. *Cah. Agric.* 26, 36001. <https://doi.org/10.1051/cagri/2017015>
- Robert, B., White, B.J., Renter, D.G., Larson, R.L., 2009. Evaluation of three-dimensional accelerometers to monitor and classify behavior patterns in cattle. *Comput. Electron. Agric.* 67, 80–84.
- Roger, C., 2001. Agriculture raisonnée, multifonctionnelle, biologique... : quelles voies vers une « agriculture durable » ? *INRA Dép. Sci. Soc. Agric. Aliment. Espace Environ.* 5p.
- Rook, A.J., Harvey, A., Parsons, A.J., Orr, R.J., Rutter, S.M., 2004. Bite dimensions and grazing movements by sheep and cattle grazing homogeneous perennial ryegrass swards. *Appl. Anim. Behav. Sci.* 88, 227–242. <https://doi.org/10.1016/j.applanim.2004.03.006>
- Rook, A.J., Tallowin, J.R.B., 2003. Grazing and pasture management for biodiversity benefit. *Anim. Res.* 52, 181–189. <https://doi.org/10.1051/animres:2003014>
- Rushen, J., Chapinal, N., de Passillé, A., 2012. Automated monitoring of behavioural-based animal welfare indicators. *Anim. Welf.* 21, 339–350. <https://doi.org/10.7120/09627286.21.3.339>
- Rutten, C.J., Velthuis, A.G.J., Steeneveld, W., Hogeveen, H., 2013. Sensors to support health management on dairy farms. *J. Dairy Sci.* 1928–1952.
- Rutter, S.M., 2000. Graze: A program to analyze recordings of the jaw movements of ruminants. *Behav. Res. Methods Instrum. Comput.* 32, 86–92. <https://doi.org/10.3758/BF03200791>
- Rutter, S.M., Champion, R.A., Penning, P.D., 1997. An automatic system to record foraging behaviour in free-ranging ruminants. *Appl. Anim. Behav. Sci.* 54, 185–195. [https://doi.org/10.1016/S0168-1591\(96\)01191-4](https://doi.org/10.1016/S0168-1591(96)01191-4)
- Rutter, S.M., Orr, R.J., Yarrow, N.H., Champion, R.A., 2004. Dietary Preference of Dairy Cows Grazing Ryegrass and White Clover. *J. Dairy Sci.* 87, 1317–1324. [https://doi.org/10.3168/jds.S0022-0302\(04\)73281-6](https://doi.org/10.3168/jds.S0022-0302(04)73281-6)
- Ruuska, S., Kajava, S., Mughal, M., Zehner, N., Mononen, J., 2016. Validation of a pressure sensor-based system for measuring eating, rumination and drinking behaviour of dairy cattle. *Appl. Anim. Behav. Sci.* 174, 19–23. <https://doi.org/10.1016/j>

- Schlecht, E., Dickhoefer, U., Gumpertsberger, E., Buerkert, A., 2009. Grazing itineraries and forage selection of goats in the Al Jabal al Akhdar mountain range of northern Oman. *J. Arid Environ.* 73, 355–363. <https://doi.org/10.1016/j.jaridenv.2008.10.013>.
- Schneider, A., Huyghe, C., 2015. Les légumineuses pour des systèmes agricoles et alimentaires durables. éditions Quae. <https://doi.org/10.35690/978-2-7592-2335-0>
- Schütz, K.E., Rogers, A.R., Poulouin, Y.A., Cox, N.R., Tucker, C.B., 2010. The amount of shade influences the behavior and physiology of dairy cattle 93, 9.
- Sellers, W.I., Crompton, R.H., 2004. Automatic Monitoring of Primate Locomotor Behaviour Using Accelerometers. *Folia Primatol. (Basel)* 75, 279–293. <https://doi.org/10.1159/000078939>
- Seuret, J.-M., Theau, J.-P., Pottier, E., Pelletier, P., Piquet, M., Delaby, L., 2014a. Des outils d'aide à la gestion du pâturage pour mieux valoriser les prairies et renforcer la confiance des éleveurs. *Fourrages* 218, 191–201.
- Seuret, J.-M., Theau, J.-P., Pottier, E., Pelletier, P., Piquet, M., Delaby, L., 2014b. Des outils d'aide à la gestion du pâturage pour mieux valoriser les prairies et renforcer la confiance des éleveurs. *Fourrages* 218, 191–201.
- Sevilla Guzmán, E., 2013. Agroecology and Sustainable Food Systems. *Agroecol. Found. Agrar. Soc. Thought Sociol. Theory* 7, 32–44.
- Shahriar, Md.S., Smith, D., Rahman, A., Freeman, M., Hills, J., Rawnsley, R., Henry, D., Bishop-Hurley, G., 2016. Detecting heat events in dairy cows using accelerometers and unsupervised learning. *Comput. Electron. Agric.* 128, 20–26. <https://doi.org/10.1016/j.compag.2016.08.009>
- Shi, H., Wang, H., Huang, Y., Zhao, L., Qin, C., Liu, C., 2019. A hierarchical method based on weighted extreme gradient boosting in ECG heartbeat classification. *Comput. Methods Programs Biomed.* 171, 1–10. <https://doi.org/10.1016/j.cmpb.2019.02.005>
- Shoaib, M., Scholten, H., Havinga, P.J.M., 2013. Towards Physical Activity Recognition Using Smartphone Sensors, in: 2013 IEEE 10th International Conference on Ubiquitous Intelligence and Computing and 2013 IEEE 10th International Conference on Autonomic and Trusted Computing. Presented at the 2013 IEEE 10th International Conference on Ubiquitous Intelligence & Computing and 2013 IEEE 10th International Conference on Autonomic & Trusted Computing (UIC/ATC), IEEE, Italy, pp. 80–87. <https://doi.org/10.1109/UIC-ATC.2013.43>
- Siivonen, J., Taponen, S., Hovinen, M., Pastell, M., Lensink, B.J., Pyörälä, S., Hänninen, L., 2011. Impact of acute clinical mastitis on cow behaviour. *Appl. Anim. Behav. Sci.* 132, 101–106. <https://doi.org/10.1016/j.applanim.2011.04.005>
- Smith, D., Rahman, A., Bishop-Hurley, G.J., Hills, J., Shahriar, S., Henry, D., Rawnsley, R., 2016. Behavior classification of cows fitted with motion collars: Decomposing multi-class classification into a set of binary problems. *Comput. Electron. Agric.* 131, 40–50. <https://doi.org/10.1016/j.compag.2016.10.006>
- Soullignac, V., Leveau, L., Pinet, F., Bergez, J.-É., 2019. Les technologies de l'information et de la communication dans la transition agroécologique. *Sci. Eaux Territ. Numéro* 29, 34. <https://doi.org/10.3917/set.029.0034>
- Starmer, J., 2019a. Gradient Boost Part 3: Classification [WWW Document]. URL https://www.youtube.com/results?search_query=statquest+gradient+boost+part+3
- Starmer, J., 2019b. Gradient Boosting Part 4 : Classification Details [WWW Document]. URL <https://www.youtube.com/watch?v=StWY5QWMXCw&t=209s>
- Starmer, J., 2020. XGBoost : Part 2: XGBoost Trees For Classification [WWW Document]. URL <https://www.youtube.com/watch?v=8b1JEDvenQU>

- Subasi, A., Dammas, D.H., Alghamdi, R.D., Makawi, R.A., Albiety, E.A., Brahimi, T., Sarirete, A., 2018. Sensor based human activity recognition using adaboost ensemble classifier. *Procedia Comput. Sci.* 140, 104–111. <https://doi.org/10.1016/j.procs.2018.10.298>.
- Theau, J.P., Cruz, P., Fallour, D., Jouany, E., Lecloux, E., Duru, M., 2010. Une méthode simplifiée de relevé botanique pour une caractérisation agronomique des prairies permanentes. *Fourrages* 201, 19–25
- Therneau, T., Atkinson, B., 2018. rpart: Recursive Partitioning and Regression Tree. R package version 4.1-13. <https://CRAN.R-project.org/package=rpart>.
- Umstatter, C., 2011. The evolution of virtual fences: A review. *Comput. Electron. Agric.* 75, 10–22. <https://doi.org/10.1016/j.compag.2010.10.005>
- Vázquez Diosdado, J.A., Barker, Z.E., Hodges, H.R., Amory, J.R., Croft, D.P., Bell, N.J., Codling, E.A., 2015. Classification of behaviour in housed dairy cows using an accelerometer-based activity monitoring system. *Anim. Biotelemetry* 3. <https://doi.org/10.1186/s40317-015-0045-8>
- Venturi, R., 2015. The Digital Revolution – An Industrial Revolution? *France Stratégie*.
- Veltink, P.H., Bussmann, H.J., de Vries, W., Martens, W.J., Van Lummel, R.C., 1996. Detection of static and dynamic activities using uniaxial accelerometers. *IEEE Trans. Rehabil. Eng.* 4, 375–385. <https://doi.org/10.1109/86.547939>.
- Vermunt, J.J., Greenough, P.R., 1995. Structural characteristics of the bovine claw: Horn growth and wear, horn hardness and claw conformation. *Br. Vet. J.* 151, 157–180. [https://doi.org/10.1016/S0007-1935\(95\)80007-7](https://doi.org/10.1016/S0007-1935(95)80007-7)
- Walker, J.S., Jones, M.W., Laramee, R.S., Holton, M.D., Shepard, E.L., Williams, H.J., Scantlebury, D.M., Marks, N., Magowan, E.A., Maguire, I.E., Bidder, O.R., Di Virgilio, A., Wilson, R.P., 2015. Prying into the intimate secrets of animal lives; software beyond hardware for comprehensive annotation in ‘Daily Diary’ tags. *Mov. Ecol.* 3. <https://doi.org/10.1186/s40462-015-0056-3>.
- Watanabe, N., Sakanoue, S., Kawamura, K., Kozakai, T., 2008. Development of an automatic classification system for eating, ruminating and resting behavior of cattle using an accelerometer. *Grassl. Sci.* 7.
- Webster, J., Stewart, M., Rogers, A., Verkerk, G., 2008. Assessment of welfare from physiological and behavioural responses of New Zealand dairy cows exposed to cold and wet conditions. *Anim. Welf.* 8.
- Wechsler, B., 1995. Coping and coping strategies: a behavioural view. *Appl. Anim. Behav. Sci.* 43, 123–134. [https://doi.org/10.1016/0168-1591\(95\)00557-9](https://doi.org/10.1016/0168-1591(95)00557-9)
- de Weerd, N., van Langevelde, F., van Oeveren, H., Nolet, B.A., Kölzsch, A., Prins, H.H., de Boer, W.F., 2015. Deriving animal behaviour from high-frequency GPS: tracking cows in open and forested habitat. *Plos One* 17. <https://doi.org/10.1371/journal.pone.0129030>.
- Weizheng, S., Fei, C., Yu, Z., Xiaoli, W., Qiang, F., Yonggen, Z., 2019. Automatic recognition of ingestive-related behaviors of dairy cows based on triaxial acceleration. *Inf. Process. Agric.* S2214317319301921. <https://doi.org/10.1016/j.inpa.2019.10.004>
- Werner, J., Leso, L., Umstatter, C., Niederhauser, J., Kennedy, E., Geoghegan, A., Shalloo, L., Schick, M., O’Brien, B., 2018. Evaluation of the RumiWatchSystem for measuring grazing behaviour of cows. *J. Neurosci. Methods* 300, 138–146. <https://doi.org/10.1016/j.jneumeth.2017.08.022>
- Werner, J., Umstatter, C., Kennedy, E., Grant, J., Leso, L., Geoghegan, A., Shalloo, L., Schick, M., O’Brien, B., 2019. Identification of possible cow grazing behaviour indicators for restricted grass availability in a pasture-based spring calving dairy system. *Livest. Sci.* 220, 74–82. <https://doi.org/10.1016/j.livsci.2018.12.004>

- Widowski, T.M., 2001. Shade-Seeking Behavior of Rotationally-Grazed Cows and Calves in a Moderate Climate, in: Livestock Environment VI, Proceedings of the 6th International Symposium 2001. Presented at the Livestock Environment VI, Proceedings of the 6th International Symposium 2001, American Society of Agricultural and Biological Engineers. <https://doi.org/10.13031/2013.7126>
- Williams, L.R., Fox, D.R., Bishop-Hurley, G.J., Swain, D.L., 2019. Use of radio frequency identification (RFID) technology to record grazing beef cattle water point use. *Comput. Electron. Agric.* 156, 193–202. <https://doi.org/10.1016/j.compag.2018.11.025>
- Willshire, J.A., Bell, N.J., 2009. An Economic Review of Cattle Lameness 17, 136–141.
- Wilson, R., Shepard, E., Liebsch, N., 2008. Prying into the intimate details of animal lives: use of a daily diary on animals. *Endanger. Species Res.* 4, 123–137. <https://doi.org/10.3354/esr00064>.
- Witten, I.H., Frank, E., 2011. *Data Mining: Practical Machine Learning Tools and Techniques*. Elsevier <https://doi.org/10.1016/C2009-0-19715-5>.
- Yadav, A., 2018. Support Vector Machines (SVM) [WWW Document]. *Data Sci.* URL <https://towardsdatascience.com/support-vector-machines-svm-c9ef22815589>
- Yang, J., 2009. Toward physical activity diary: motion recognition using simple acceleration features with mobile phones, in: *Proceedings of the 1st International Workshop on Interactive Multimedia for Consumer Electronics*. ACM, pp. 1–10.
- Yunta, C., Guasch, I., Bach, A., 2012. Short communication: Lying behavior of lactating dairy cows is influenced by lameness especially around feeding time. *J. Dairy Sci.* 95, 6546–6549. <https://doi.org/10.3168/jds.2012-5670>
- Zaccarelli, N., Li, B.-L., Petrosillo, I., Zurlini, G., 2013. Order and disorder in ecological time-series: introducing normalized spectral entropy. *Ecol. Indic.* 28, 22–30. <https://doi.org/10.1016/j.ecolind.2011.07.008>.
- Zebari, H.M., Rutter, S.M., Bleach, E.C.L., 2018. Characterizing changes in activity and feeding behaviour of lactating dairy cows during behavioural and silent oestrus. *Appl. Anim. Behav. Sci.* 206, 12–17. <https://doi.org/10.1016/j.applanim.2018.06.002>
- Zhao, Y., Lehman, B., Ball, R., Mosesian, J., de Palma, J.-F., 2013. Outlier detection rules for fault detection in solar photovoltaic arrays, in: *2013 Twenty-Eighth Annual IEEE Applied Power Electronics Conference and Exposition (APEC)*. Presented at the 2013 IEEE Applied Power Electronics Conference and Exposition - APEC 2013, IEEE, Long Beach, CA, USA, pp. 2913–2920. <https://doi.org/10.1109/APEC.2013.6520712>

Annexes

Annexe I. Des outils de simulation pour faciliter la gestion du pâturage.....	1
Annexe II. Diversité des cadres expérimentaux mis en place dans les différentes études	4
Annexe III. Méthodes utilisées dans chacune des études prises en compte	7
Annexe IV. Equation des principales variables utilisées dans la littérature	11
Annexe V. Performances de classification obtenues dans chacune des études considérées	12
Annexe VI. Principe de l’algorithme de l’arbre de décision appliqué à un problème de classification.....	15
Annexe VII. Principe de l’algorithme de Support Vector Machines	18
Annexe VIII. Principe de l’algorithme de forêt aléatoire pour la classification	23
Annexe IX. Principe de l’algorithme AdaBoost	26
Annexe X. Principe de l’algorithme de gradient boosting et cas particulier de l’eXtreme Gradient Boosting.....	31
Annexe XI. Définition du HMM et principe de l’algorithme de Viterbi.....	40

Annexe I. Des outils de simulation pour faciliter la gestion du pâturage

❖ Outils statiques

Outre l'herbomètre à plateau conçu en Nouvelle-Zélande (modèle néo-zélandais, « Jenquip »), les premiers outils développés dans les années 1980 ont d'abord eu vocation à faciliter la traçabilité des actions entreprises par les éleveurs au cours de la saison de pâturage. C'est notamment le cas des plannings de pâturage sur lesquels le déroulement de la saison est enregistré au jour le jour, garantissant une visualisation plus rapide de l'ordre du passage des animaux dans les parcelles et de la succession des différents cycles de pâturage. Les dates clés de la gestion du pâturage sont également notées sur le planning, notamment la date de mise à l'herbe, de sortie des vaches la nuit, de fermeture et réouverture du silo de maïs ainsi que la date de fin de saison de pâturage. Ces plannings permettent ainsi de décider plus facilement des parcelles à faire pâturer à très court terme, mais garantissent aussi une traçabilité pour les années à venir dans une perspective d'amélioration.

❖ Outils semi-dynamiques

Les outils semi-dynamiques proposés à partir des années 2000 s'appuient au contraire sur le développement de l'informatique, avec pour objectif d'améliorer la valorisation des mesures de hauteurs d'herbe et indicateurs associés. Ces outils permettent notamment de faciliter le calcul des indicateurs à partir de données sur la prairie et sur les animaux, de proposer des valeurs cibles pour chacun des indicateurs et éventuellement d'estimer le devenir de ces indicateurs à court terme selon différentes options de gestion du troupeau et de pousse de l'herbe. La spécificité de chacun des outils repose surtout sur l'indicateur valorisé en sortie. Les outils Herb'ITCF® puis Herbo-LIS® proposés par Arvalis - Institut du végétal, Herb'Avenir développé par les Chambres d'agriculture de Bretagne et par l'INRA (Institut National de Recherche Agronomique) et Pasture Base conçu en Irlande sont des exemples d'outils semi-dynamiques d'aide à la gestion du pâturage. La description, les données d'entrée et les données de sortie propres à chacun de ces trois outils sont présentés dans le tableau ci-après

Principaux outils semi-dynamiques d'aide à la gestion du pâturage.

D'après : Seuret et al. Des outils d'aide à la gestion du pâturage pour mieux valoriser les prairies et renforcer la confiance des éleveurs. *Fourrages*. 2014.

Outil	Description	Données d'entrée	Données de sortie
Herb'ITCF, Herbo-LIS	Fournit des conseils sur les décisions à prendre selon le nombre de jours d'avance.	Caractéristiques des parcelles (surface, type de prairie), hauteur d'herbe dans chaque parcelle, nombre d'animaux, potentiel de production, période de l'année.	Hauteur sortie conseillée, nombre de jours d'avance dans l'exploitation, nombre de jours d'avance conseillés, conseils en cas d'excès ou de déficit de jours d'avance.
Herb'Avenir	Évalue le stock d'herbe actuel à partir de mesures de hauteurs d'herbe et estime les conséquences sur ce stock selon différentes options de gestion du troupeau et de pousse de l'herbe.	Caractéristiques des parcelles (surface, type de prairie), hauteur d'herbe de chaque parcelle, caractéristiques des animaux, options de complémentation pour le mois à venir.	Stock d'herbe par animal le jour des mesures, 15 jours et un mois après la date des mesures.
Pasture Base	Trace le profil de pâturage* pour des parcelles de même taille à partir des hauteurs d'herbe mesurées et fournit la couverture herbagère cible.	Caractéristiques des parcelles (surface, type de prairie), hauteur d'herbe sur chaque parcelle, chargement, potentiel de production des animaux.	Couverture herbagère de l'ensemble des paddocks, profil de pâturage, conseil en cas d'excès ou de déficit d'herbe.

Note :

*Le profil de pâturage correspond au disponible en herbe dans chaque paddock calculé chaque semaine et exprimé en kg MS par hectare. Le disponible dans chaque paddock est ensuite comparé au « disponible en herbe idéal » qui découle d'un calcul de la biomasse cible à la sortie, du chargement, de l'ingestion et de la durée de rotation. Cette approche permet de savoir chaque semaine quels paddocks faire pâturer et dans quel ordre. Le profil de pâturage a donné par la suite naissance à d'autres outils comme le Feed Budget Rotation Planner en Australie ou l'abaque pâturage en Belgique.

❖ Outils dynamiques

Les outils dynamiques permettent de faire en plus des simulations sur plusieurs semaines afin d'évaluer les conséquences des différentes stratégies de gestion du pâturage et de l'alimentation dans différents contextes de climat. Ces outils sont tous basés sur des données mesurées sur la prairie et sur des informations sur les animaux. Les volets traités par ces outils sont également globalement similaires. Ils ont généralement un volet tactique permettant d'enregistrer

informatiquement les informations au pâturage ainsi qu'un volet stratégique permettant de simuler différentes actions du pâturage et d'évaluer leurs conséquences à moyen terme. Les principales différences entre outils se situent au niveau des données de sortie qui sont valorisées. L'outil Patur'IN (Delaby et al., 2001) développé par l'INRA, Herb'Evol conçu par l'INRA et les chambres d'agriculture de Bretagne ainsi que Patur'Plan mis en place par l'INRA et les chambres d'Agriculture de l'Orne sont des exemples d'outils dynamiques d'aide à la gestion du pâturage. La description, les données d'entrée et les données de sortie propres à chacun de ces trois outils sont présentés dans le tableau suivant.

Principaux outils semi-dynamiques d'aide à la gestion du pâturage.

D'après : Seuret et al. Des outils d'aide à la gestion du pâturage pour mieux valoriser les prairies et renforcer la confiance des éleveurs. *Fourrages*. 2014.

Outil	Description	Données d'entrée	Données de sortie
Patur'IN	<p><u>Volet tactique</u> : enregistrement informatique des actions au pâturage</p> <p><u>Volet stratégique</u> : simulation de l'impact d'une décision de gestion du pâturage</p>	Caractéristiques des parcelles et du troupeau ; profil de croissance de l'herbe standardisée et de densité de l'herbe.	<p><u>Pour chaque parcelle</u> : temps de repousse, hauteur, biomasse, croissance, densité et ingestion d'herbe</p> <p><u>Pour plusieurs parcelles</u> : SHD, nombre de jours d'avance, croissance.</p> <p><u>Pour le troupeau</u> : ingestion d'herbe et de compléments</p>
Herb'Evol	<p><u>Volet tactique</u> : enregistrement informatique des actions au pâturage</p> <p><u>Volet stratégique</u> :</p> <ul style="list-style-type: none"> - Simulation de l'impact d'une décision - édition bilan fin d'année 	Caractéristiques des parcelles et des animaux, dates de présence sur les différentes parcelles, dates de fauche et fertilisation, quantité compléments.	Temps de repousse des différentes parcelles, durée du cycle de pâturage, rendement d'herbe par parcelle, bilan de la quantité d'herbe valorisée sur l'année, calendrier prévisionnel de pâturage.
Patur'Plan	<p><u>Volet stratégique</u> :</p> <ul style="list-style-type: none"> - Evolution future profil de pâturage en simulant la croissance de l'herbe et l'utilisation des parcelles. - Estime les conséquences de choix de gestion du troupeau sur le pâturage. 	Caractéristiques des parcelles (surface, type de prairie), hauteur d'herbe, potentiel de production et ration des animaux.	Profil de pâture à partir de mesures des hauteurs d'herbe, calcul de la biomasse et du temps de séjour par parcelle

Références

- Delaby, L., Peyraud, J.L., Faverdin, P., 2001. Pâtur' IN : le pâturage des vaches laitières assisté par ordinateur. *Fourrages* 385–398.
- Seuret, J.-M., Theau, J.-P., Pottier, E., Pelletier, P., Piquet, M., Delaby, L., 2014. Des outils d'aide à la gestion du pâturage pour mieux valoriser les prairies et renforcer la confiance des éleveurs. *Fourrages* 218, 191–201.

Annexe II. Diversité des cadres expérimentaux mis en place dans les différentes études

Référence	Acquisition données accéléromètres				Technologie	Acquisition observations	
	Espèce (race)	Nombre	Durée tot.*	Position capteur	Freq.**	Comportements***	Durée encodage
Nadimi et al., 2008	Bovin (non précisé)	4	6 h/j * 3 j	Au niveau de la nuque	1 Hz	Actif ; Inactif	Non précisé
Watanabe et al., 2008	Bovin (Holstein (exp1) + Japanese Black (exp2))	1 (exp1) + 1 (exp2)	4 h (exp1) + 4 * 3 h (exp2)	En dessous de la mâchoire	32 Hz	exp1 : Ingestion ; Rumination ; Repos exp2 : Ingestion ; Rumination ; Repos	4 heures (exp1) 12 heures (exp2)
Martiskainen et al., 2009	Bovin (Ayrshire + Holstein-Friesan)	30	≈ 3 mois	Au niveau du cou	10 Hz	Debout ; Couché ; Rumination ; Ingestion ; Marche normale ; Marche boiteuse	95.5 heures
Moreau et al., 2009	Caprin (Thüringer Waldziege x Toggenburg (exp1)) + Jabal Akhdar (exp2)	2 (exp1) + 1 (exp2)	5 j * 4 h (animal 1 + animal 2) + 6 j * 4 h (animal 1) (exp1) 7 j * 10 h (exp2)	Au niveau de la nuque A la base du cou Au milieu du dos	1 Hz (exp1) 0.5 Hz (exp2)	Marche ; Repos ; Ingestion (exp1) Ingestion ; Préhension, Mastication (exp2)	20 h (exp1) Durée inconnue (exp2)
Robert et al., 2009	Bovin (non précisé)	15	3 semaines	Face latérale du membre postérieur droit	100 Hz	Couché ; Debout ; Marche	10 heures
Hamalainen et al., 2011	Bovin (non précisé)	21	Non précisé	Au-dessus de la nuque	10 Hz	Repos ; Marche ; Se couche ; Se lève	1.98 heures
Hokkanen et al., 2011	Bovin (Western Finncattle)	10	24 heures	Au niveau du cou (côté droit)	25 Hz	Debout ; Couché éveillé ; Sommeil lent ; Sommeil paradoxal	2.20 heures
Dutta et al., 2015	Bovin (Holstein-Friesan)	24	10 jours	Au niveau du cou (côté droit)	10 Hz	Ingestion ; Rumination ; Repos ; Marche ; Autre	6 heures

Vázquez Diosdado et al., 2015	Bovin (Holstein)	6	2 jours	Au niveau du cou (côté droit)	50 Hz	Ingestion ; Debout ; Couché ; Se couche ; Se lève	33.3 heures
Gonzalez et al., 2015	Bovin (Brahman + Belmont Red + croisement)	58	40 jours	En dessous du cou	10 Hz	Ingestion ; Ruminantion ; Marche ; Repos ; Autre	58 heures
Alvarenga et al., 2016	Ovin (Merino)	4 (exp1) + 6 (exp2)	6 jours (exp1) + 2 jours (exp2)	En dessous du cou	5 Hz 10 Hz 25 Hz	Ingestion ; Couché ; Court ; Debout ; Marche	3.36 heures
Mattachini et al., 2016	Bovin (Holstein-Friesan)	12	3 heures	Au niveau du cou	2 Hz	Ingestion	3 heures
Smith et al., 2016	Bovin (Holstein-Friesan)	24	14 jours	Au niveau du cou, à gauche	10 Hz	Ingestion ; Marche ; Ruminantion ; Repos ; Autre	48 heures
Abell et al., 2017	Bovin (Angus + croisement)	2	3 jours	A l'oreille Sur le dos Au-dessus de la nuque	1 Hz	Couché ; Debout ; Marche ; Chevauchement ; Autre	Non précisé
Andriamandroso et al., 2017	Bovin (pie-rouge Holstein + pie-noire Holstein + Blonde d'Aquitaine x Blanc Bleu Belge + Blanc Bleu Belge)	19	3 sessions * 2 mois	Au-dessus de la nuque	100 Hz	Ingestion ; Ruminantion ; Autre	≈ 44 heures
Arcidiacono et al., 2017	Bovin (non précisé)	5	5 heures	Au-dessus de la nuque	4 Hz	Ingestion ; Debout	5 heures
Benaissa et al., 2017	Bovin (Holstein)	16	6 heures	Au niveau du cou (côté droit) Sur le membre postérieur droit	1 Hz	Couché ; Debout ; Ingestion	96 heures
Giovanetti et al., 2017	Ovin (Sarde)	2	6 jours	En dessous du cou	62.5 Hz	Ingestion ; Ruminantion ; Repos	42 heures
Barwick et al., 2018	Ovin (Merino x Poll Dorset)	5		Au niveau du cou Sur le membre antérieur droit	12 Hz	Ingestion ; Debout ; Couché ; Marche	12.5 heures

				Sur l'oreille droite			
Benaissa et al., 2018	Bovin (Holstein)	10	5 jours	Au niveau du cou (côté droit)	10 Hz	Ingestion ; Rumination ; Autre	60 heures
Decandia et al., 2018	Ovin (Sarde)	8	6 h * 4 j	En dessous de la mâchoire	62.5 Hz	Ingestion ; Rumination ; Autre	≈ 3 heures
Kamminga et al., 2018	Caprin (non précisé)	5	2 * 4 h * 7 j	6 positions différentes sur un collier autour du cou.	100 Hz	Stationnaire ; Ingestion ; Marche ; Trotte ; Court ; Se bat ; Se secoue ; Passe par-dessus/escalade un objet ; Passe en dessous d'un objet ; Marche en poussant la clôture ; Pousse les autres pour accéder à la nourriture	117.6 heures
Lush et al., 2018	Ovin (Welsh moutain)	30	30 jours	Sur le dos	40 Hz	Ingestion ; Marche ; Court ; Debout ; Couché ; Urination ; Se gratte ; Se lève ; Interaction	5.58 heures
Rahman et al., 2018	Bovin (non précisé)	7	Non précisé	Au niveau du cou (côté gauche) A proximité de la mâchoire (côté gauche) Sur l'oreille gauche	30 Hz 12 Hz	Ingestion ; Debout ; Repos ; Marche ; Rumination ; Autre	Non précisé
Weizheng et al., 2019	Bovin (Holstein)	5	17 jours	En dessous de la mâchoire	5 Hz	Ingestion ; Rumination ; Autre	50.6 heures

Note :

*Durée totale pendant laquelle les animaux ont été équipés avec le/les accéléromètre(s).

** Fréquence d'échantillonnage des capteurs utilisés

*** Comportements encodés pendant la phase d'observation des animaux.

Les comportements observés au pâturage sont écrits sur fond vert ; les comportements observés au bâtiment sont écrits sur fond orange.

Annexe III. Méthodes utilisées dans chacune des études prises en compte

Référence	Traitement signal brut				Classification	Validation		
	Filtrage (type de filtre)	Séries temporelles	Segmentation (type ; taille)	Variables (domaine ; type)		Méthode* calibration(%)/validation(%)		Métriques
Nadimi et al., 2008	Isolation composante statique (moyenne glissante)	<i>pitch</i>	Fixe ; 17 min	Temporel ; orientation	Arbre de décision	CV (75/25)		% de bon classement
Watanabe et al., 2008	Aucun	Accx, Accy, Accz, Amag	Fixe ; 60 s	Temporel ; niveau d'activité, type de mouvement	QDA	Bootstrap (67/33)		% de bon classement
Martiskainen et al., 2009	Aucun	Accx, Accy, Accz	Fixe ; 10 s	Temporel ; niveau d'activité, type de mouvement ; orientation	SVM	JDE/JDT (70/30)		% de bon classement ; Kappa ; sensibilité ; spécificité ; précision
Moreau et al., 2009	Aucun	Accx, Accy, Accz	Fixe ; 1 s à 20 s	Temporel ; niveau d'activité, orientation	Seuillage	exp1 CV (50/50)	exp2 CV (57/33)	% de bon classement ; concordance statistique
Robert et al., 2009	Aucun	Accx, Accy, Accz, Amag	Fixe ; 3 s, 5 s, 10 s	Temporel ; niveau d'activité, orientation	Arbre de décision	JDE/JDT (70/30)		% de bon classement
Hamalainen et al., 2011	Isolation de l'accélération <i>jerk</i> et angle <i>jerk</i> (filtre <i>jerk</i>)	Accélération <i>jerk</i> Angle <i>jerk</i>	Non précisé	Temporel ; niveau d'activité, orientation de l'animal	Arbre de décision	CV (90/10)		% de bon classement
Hokkanen et al., 2011	Aucun	Accx	Fixe ; 20 s	Temporel ; niveau d'activité Temps-fréquence : 5 premiers niveaux	SVM	LOOV (90/10)		% de bon classement
Dutta et al., 2015	Aucun	Accx, Accy, Accz	Fixe ; 5 s	Temporel ; niveau d'activité, type de mouvement, orientation	<u>Classifieurs individuels</u> : arbre de décision ; LDA ; NB ; kNN ; ANFIS <u>Ensemble de classifieurs</u> : <i>Bagging</i> + <i>Boosting</i> (Adaboost) avec	JDE/JDT (50/50)		% de bon classement ; Fscore ; taux de faux positifs; sensibilité ; spécificité

					LDA + arbre de décision ; Random Subspace avec kNN		
Vázquez Diosdado et al., 2015	Isolation composante statique (moyenne glissante)	VeDBA AccySt	Fixe ; 1 min, 5 min, 10 min	Temporel ; niveau d'activité, orientation	Arbre de décision (seuillage ?) ; k-means ; HMM ; SVM	Non précisé	sensibilité ; précision
Gonzalez et al., 2015	Aucun	Accx, Accy, Accz	Fixe ; 10 s	Temporel ; niveau d'activité, orientation	Seuillage	JDE/JDT (75/25)	précision ; sensibilité ; spécificité ; concordance statistique
Alvarenga et al., 2016	Aucun	Accx, Accy, Accz	Fixe ; 3 s, 5 s, 10 s	Temporel ; niveau d'activité, type de mouvement, orientation	Arbre de décision	JDE/JDT (70/30)	% de bon classement ; précision ; sensibilité ; spécificité
Mattachini et al., 2016	Isolation composante statique (méthode non précisée)	AccxSt, AccySt, AcczSt	Aucune	Temporel ; orientation	Seuillage	Jeu de données pour seuillage = jeu de données de validation	sensibilité ; spécificité ; valeur prédictive positive (précision) ; valeur prédictive négative
Smith et al., 2016	Isolation composante dynamique (filtre passe-haut 0.3 Hz)	AccxDy, AccyDy, AcczDy, Amag, <i>pitch</i> , <i>roll</i>	Fixe ; 1.5 s, 2.5 s, 5 s, 7.5 s, 10 s, 15 s, 20 s, 25 s, 30 s	Temporel ; niveau d'activité, type de mouvement, orientation Fréquentiel : Type de mouvements	SVM ; NB ; kNN ; LR ; RF	CV (87.5/12.5)	Fscore ; sensibilité ; précision
Abell et al., 2017	Isolation composante statique (moyenne glissante)	Accx, Accy, Accz, AccxSt, AccySt, AcczSt	Non précisé	Temporel ; niveau d'activité, type de mouvement, orientation	Arbre aléatoire, arbre de décision, RF	JDE/JDT (50(+25)/25)	% de bon classement ; valeur prédictive positive ; valeur prédictive négative sensibilité ; spécificité

Andriamandroso et al., 2017	Réduction du bruit (normalisation du signal brut) Isolation de fréquences particulières (filtre passe bande [1 Hz ; 2Hz])	AccxDy, AccyDy, AcczDy, AccxSt, AccySt, AcczSt	Fixe ; 1 s, 5 s, 10 s, 15 s, 30 s, 60 s	Temporel ; niveau d'activité, orientation	Seuillage	JDE/JDT (7/93)	% de bon classement ; sensibilité ; spécificité ; précision
Arcidiacono et al., 2017	Aucun	Accx	Fixe ; 5 s	Temporel ; niveau d'activité	Seuillage	JDE/JDT (70/30)	Taux d'erreur ; sensibilité ; spécificité ; précision
Benaissa et al., 2017	Isolation composante dynamique (soustraction moyenne glissante)	Amag, OBDA, VeDBA	Fixe ; 60 s	Temporel ; niveau d'activité Fréquentiel : type de mouvement	kNN, NB, SVM	LOOV (93/7)	% de bon classement ; sensibilité ; précision
Giovanetti et al., 2017	Aucun	Accx, Accy, Accz, Amag	Fixe ; 60 s	Temporel ; niveau d'activité, orientation ; type de mouvement	LDA	<i>Bootstrap</i> (75/25)	% de bon classement ; sensibilité ; spécificité ; précision ; Kappa
Barwick et al., 2018	Aucun	Accx, Accy, Accz, Amag	Fixe ; 10 s	Temporel ; niveau d'activité, orientation ; type de mouvement	QDA	LOOV (0.2/99.8)	% de bon classement ; sensibilité ; spécificité ; précision
Benaissa et al., 2018	Isolation composante dynamique (filtre passe bas puis soustraction à l'accélération brute)	OBDA	Fixe ; 60 s	Temporel ; niveau d'activité	Arbre de décision ; SVM	LOOV (90/10)	% de bon classement ; sensibilité ; spécificité ; précision
Decandia et al., 2018	Aucun	Accx, Accy, Accz, Amag	Fixe ; 5 s , 10 s, 30 s, 60 s, 120 s, 180 s, 300 s	Temporel ; niveau d'activité, orientation ; type de mouvement	LDA	<i>Bootstrap</i> (75/25)	% de bon classement ; sensibilité ; spécificité ; précision ; Kappa

Kamminga et al., 2018	Isolation composante statique (filtre passe-bas) + isolation composante dynamique (filtre passe-haut)	Accx, Accy, Accz, Amag, AccxDy, AccyDy, AcczDy	Fixe ; RECV : 50 % 2 s	Temporel ; niveau d'activité, orientation ; type de mouvement Fréquentiel : type de mouvement	Arbre de décision ; réseau de neurones ; SVM ; NB ; LDA ; kNN	Animal jeu de données entraînement = animal jeu de données de validation		% de bon classement ; sensibilité ; précision ; Fscore (uniquement fournis pour NB et DT)
Lush et al., 2018	Isolation composante statique (moyenne glissante) + composante dynamique (soustraction moyenne glissante à l'accélération brute)	Accx, Accy, Accz, AccxDy, AccyDy, AcczDy, VeDBA, <i>pitch, sway</i>	Fixe ; 3 s, 5 s, 10 s	Temporel ; niveau d'activité, orientation ; type de mouvement Fréquentiel : type de mouvement	RF	JDE/JDT (75/25)		% de bon classement, sensibilité, précision, Kappa
Rahman et al., 2018	Aucun	Amag	Fixe ; 6.6 s, 16.6 s	Temporel ; niveau d'activité, type de mouvement Fréquentiel : type de mouvement	RF	CV (80/20)	LOOV (85/15)	Fscore
Weizheng et al., 2019	Isolation composante dynamique (soustraction moyenne glissante à l'accélération brute)	Amag, OBDA, VeDBA	Fixe ; 6.4 s, 12.8 s, 25.6 s, 51.2 s	Temporel ; niveau d'activité, type de mouvement Fréquentiel : type de mouvement	kNN, SVM et réseau de neurones probabiliste	LOOV (80/20)		% bien classés, Fscore, précision, sensibilité, spécificité

Note : *Méthode utilisée pour valider l'algorithme de classification

Une validation réalisée au niveau de l'individu est marquée sur fond rose ; une validation réalisée au niveau de la période d'observation est marquée sur fond orange ; une validation réalisée au niveau de la fenêtre est marquée sur fond bleu.

Annexe IV. Equation des principales variables utilisées dans la littérature

Variable	Equation
Moyenne de l'axe x ($\overline{A_x}$)	$\overline{A_x} = \frac{1}{M} \sum_{i=1}^M a_{xi}$
Variance de l'axe x (σ_x^2)	$\sigma_x^2 = \frac{1}{M} \sum_{i=1}^M (a_{xi} - \overline{A_x})^2$
Ecart-type de l'axe x (σ_x)	$\sigma_x = \sqrt{\sigma_x^2}$
Etendue de l'axe x ($Range_x$)	$Range_x = Max_x - Min_x$
Ecart interquartile de l'axe x (IQ_x)	$IQ_x = Q_{3;x} - Q_{1;x}$
Moyenne quadratique de l'axe x (RMS)	$RMS = \sqrt{\frac{1}{M} \sum_{i=1}^M a_{xi}^2}$
Zone d'Amplitude du Signal (SMA)	$SMA = \frac{1}{M} \left(\sum_{i=1}^M a_{xi} + \sum_{i=1}^M a_{yi} + \sum_{i=1}^M a_{zi} \right)$
Intensité moyenne (AI)	$AI = \frac{1}{M} \sum_{i=1}^M a_{mag}$
Variation de mouvement (MV)	$MV = \frac{1}{M} \left(\sum_{i=1}^{M-1} a_{x,i+1} - a_{x,i} + \sum_{i=1}^{M-1} a_{y,i+1} - a_{y,i} \right. \\ \left. + \sum_{i=1}^{M-1} a_{z,i+1} - a_{z,i} \right)$
Asymétrie axe x ($\beta_{1;x}$)	$\beta_{1;x} = \frac{1}{M} \sum_{i=1}^M \left(\frac{a_{xi} - \overline{A_x}}{\sigma} \right)^3$
Aplatissement axe x ($\beta_{2;x}$)	$\beta_{2;x} = \frac{1}{M} \sum_{i=1}^M \left(\frac{a_{xi} - \overline{A_x}}{\sigma} \right)^4$
Maximum des corrélations entre les axes x et y ($Max_corr_{x;y}$)	The maximum of the correlation between the X-axis and Y-axis within the window
Entropie spectrale (H_s)	$H_s = - \sum_{k=1}^N P_k \ln(P_k)$ with $P_k = \frac{ \lambda_k ^2}{\sum_i \lambda_i ^2}$ and for the frequency λ_k

Annexe V. Performances de classification obtenues dans chacune des études considérées

Référence	Comportements	% bien classés		Kappa	Fscore		Sensibilité (%)		Spécificité (%)		Précision (%)	
Nadimi et al., 2008	Actif ; Inactif	83.2										
Watanabe et al., 2008	Ingestion ; Rumination ; Repos	94.9										
	Ingestion ; Rumination ; Repos	95.7										
Martiskainen et al., 2009	Debout	87		0.69			80				65	
	Couché	84					80				83	
	Rumination	92					75				86	
	Ingestion	96					75				81	
	Marche normale	99					79				79	
	Marche boiteuse	98					65				66	
	Se couche						0				0	
	Se lève						71				29	
Moreau et al., 2009	Marche	Exp1	82									
	Repos		73.5									
	Ingestion		89									
	Ingestion	Exp2	81.3									
	Préhension		65.6									
	Mastication		77.6									
Robert et al., 2009	Couché	99.2										
	Debout	98.0										
	Marche	67.8										
Hamalainen et al., 2011	Repos	87.9					94.3				96.5	
	Marche						87.3				82.1	
	Se couche						62.0				56.4	
	Se lève						64.1				64.1	
Hokkanen et al., 2011	Debout	89										
	Couché éveillé	40										
	Sommeil léger	8										
	Sommeil paradoxal	9										
Dutta et al., 2015	Ingestion	98	96		93	89	98	97	93	89		

	Marche	93			83		96		83		
	Rumination	97			93		99		90		
	Repos	97			93		98		92		
	Autre	82			82		94		85		
Vázquez Diosdado et al., 2015	Ingestion						98.78	88.08			93.10
	Debout						88				55
	Couché						77.42				98.63
	Se couche						66.67				83.33
	Se lève						63.64				70
Gonzalez et al., 2015	Ingestion						98.4		99.4		
	Repos						86.3		94.8		
	Rumination	90.46		0.87			87.3		95.1		
	Marche						24.7		99.9		
	Autre						0		97.9		
Alvarenga et al., 2016	Ingestion						84.3		97.3		92.9
	Couché						91.1		87.9		81.7
	Court	85.5		0.79			100		99.3		50
	Debout						77		95.5		85.7
	Marche						91.7		99		86.3
Mattachini et al., 2016	Ingestion (durée visite au distributeur)						78.9		93.7		81.9
Smith et al., 2016	Ingestion				98		99				97
	Marche				70		76				65
	Rumination				86		88				84
	Repos				85		88				83
Abell et al., 2017	Couché	99					97.9		99.5		98.9
	Debout	88.7					91.6		84.2		89.8
	Marche	77.1					80.8		76.8		23.8
	Chevauchement	78.1					80.8		78.1		99.8
Andriamandroso et al., 2017	Ingestion	91					91.1		90.9		93.5
	Rumination	96.5					53.1		99.4		84.5
	Autre	87.6					87.6		87.5		79.1
Arcidiacono et al., 2017	Ingestion	93.3	94.4				93.33		95.56		95.45
	Debout	95.5									

Benaissa et al., 2017	Debout	98						96				94		
	Ingestion							99				98		
	Couché							98				99		
Giovanetti et al., 2017	Ingestion	96	93	0.92	0.89			96		97		95		
	Rumination	95		0.86				89		97		89		
	Repos	94		0.89				93		95		94		
Barwick et al., 2018	Ingestion	86						85		88		91		
	Debout	87						69		90		56		
	Marche	100						98		100		100		
	Couché	100						100		100		100		
Benaissa et al., 2018	Autre	93						89		97		98		
	Rumination							92		96		88		
	Ingestion							85		95		92		
Decandia et al., 2018	Ingestion	94	89.7	0.80				94.8		93		94.1		
	Rumination	90						80.4		94.7		88.1		
	Autre	95.5						92.3		96		77.9		
Kamminga et al., 2018	Stationnaire ; Ingestion ; Marche ; Trotte ; Court ; Autre	93.4												
Lush et al., 2018	Ingestion	98	96	0.945				97.7		87.2		93.9		93.7
	Marche	91						91.3				90.3		
	Court	90						90				90		
	Debout	80						80.5				99.1		
	Couché	100						99.9				99.7		
	Urine	64						64				88.9		
Rahman et al., 2018	Ingestion					CV	LOOV							
						0.91	0.80							
	Debout					0.89	0.51							
	Rumine					0.98	0.62							
Weizheng et al., 2019	Ingestion	94.5				0.92		95.6		96.1		92.8		
	Rumination							94.3		97.5		93.7		
	Autre							93.7		97.9		96.7		

Note : Lorsque plusieurs méthodes ont été utilisées dans les études (position du capteur, taille de la fenêtre, classifieur, etc.), seules les meilleures performances ont été rapportées.

Définition et application

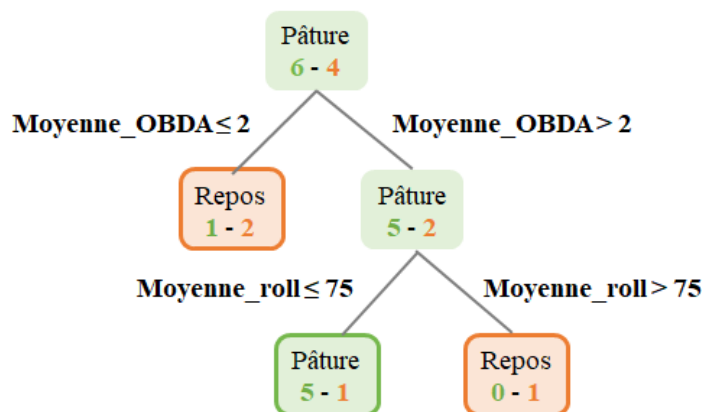
Développé par Breiman et al. en 1984, l'arbre de décision est un algorithme de *machine learning* relativement simple et intuitif qui s'applique aussi bien pour de la classification supervisée (variable à prédire qualitative) que pour de la régression (variable à prédire continue). Seuls les arbres de décision pour la classification sont présentés ici.

Principe général

Supposons un jeu de données constitué de :

- 10 fenêtres de signal : 6 fenêtres associées au comportement de pâturage et 4 autres associées au comportement de repos.
- Deux variables quantitatives : la moyenne de l'OBDA et la moyenne de la série *roll*

L'objectif est de prédire les comportements des vaches laitières à partir des variables extraites du signal. L'arbre de décision dispose donc d'un jeu de données constitué de 10 *échantillons* (les fenêtres de signal) auxquels sont associés des *variables quantitatives* (la moyenne de l'OBDA et la moyenne de la série *roll*). Chaque échantillon est associé à un comportement observé, le comportement des animaux correspondant ici aux *classes à prédire*. Une représentation possible de l'arbre de décision obtenu dans ce contexte particulier est proposée ci-après.



Légende :

- Nœud associé au comportement de pâturage
- Nœud associé au comportement de repos
-
- n Nombre d'échantillons du jeu de données associés au comportement de pâturage dans le nœud
- n Nombre d'échantillons du jeu de données associés au comportement de repos dans le nœud
- abc** Condition pour séparer le nœud parent en nœuds enfants

Dans cette représentation, la *racine* de l'arbre est située au sommet. Initialement, tous les échantillons sont présents dans la racine de l'arbre. Le texte en gras correspond à une *condition* établie sur la base des deux variables à disposition et à partir de laquelle l'arbre se divise en *branches*. Cette division donne lieu à deux *nœuds enfants* à partir d'un *nœud parent*. A chaque division, l'*impureté* des nœuds diminue progressivement. Au fur et à mesure de la descente dans l'arbre, les nœuds deviennent donc de plus en plus représentatifs d'une seule classe. Les nœuds terminaux sont appelés les *feuilles* et correspondent à la classe finale obtenue pour chaque échantillon, à savoir le comportement final affecté par l'arbre. Les conditions établies à chacune des branches pourront ensuite être utilisées pour prédire le comportement des animaux sur un nouveau jeu de données.

Condition à utiliser à chaque nœud

L'objectif est de choisir à chaque nœud la condition qui maximise la diminution d'impureté des nœuds enfants à partir du nœud parent. La pureté d'un nœud est généralement mesurée avec l'index de Gini (G) dont la formule est la suivante :

$$G = \sum_{k=1}^N (p_k * (1 - p_k))$$

Avec N le nombre de classes, *i.e.* de comportements, et p_k la proportion d'échantillons correspondant au comportement k dans le nœud.

Dans cet exemple où il y a deux comportements à prédire, le minimum d'impureté (proportion 0-100) conduit à $G = 0$ et le maximum d'impureté (proportion 50-50) conduit à $G = 0.5$. A chaque nœud, la condition retenue est celle qui minimise le critère G .

Profondeur de l'arbre

Dans le cas où le jeu de données est plus conséquent et où il y a plus de classes à prédire, un certain nombre de nœuds et branches sont nécessaires pour aboutir aux feuilles terminales : on parle de *profondeur* de l'arbre. Celle-ci conditionne directement le niveau de complexité de l'arbre et nécessite d'être contrôlée. Un arbre trop complexe peut en effet conduire à une prédiction médiocre sur un jeu de données indépendant. Cette situation a lieu lorsque l'arbre établi est trop spécifique du jeu de données d'entraînement et n'est pas assez générique : on parle alors de *sur-ajustement* du modèle. La profondeur de l'arbre peut être contrôlée en imposant un nombre minimal d'échantillons dans chaque nœud ou en fixant un nombre maximal de branches à ne pas dépasser par exemple.

Elagage de l'arbre

Une fois que l'arbre a été obtenu, ses performances peuvent être améliorées par élagage. Cette étape consiste à supprimer les branches qui utilisent des variables dont l'importance relative est faible. Elle permet ainsi d'améliorer le pouvoir prédictif de l'arbre en réduisant sa complexité, et par suite, le sur-ajustement. Une méthode d'élagage couramment utilisée consiste à construire une suite de sous-arbres à partir de l'arbre maximal en l'élagant successivement. L'arbre élagué choisi parmi cette suite est celui qui garantit le meilleur compromis entre la taille de l'arbre et son coût de mauvais classement. D'un point de vue algorithmique, cela revient à minimiser le critère de complexité α , défini par Breiman de la manière suivante :

$$\alpha = \frac{\varepsilon(\text{elagué}(T, f), E) - \varepsilon(T, E)}{\text{nombre_feuilles}(T) - \text{nombre_feuilles}(\text{elagué}(T, f))}$$

avec $\text{elagué}(T, f)$ l'arbre T élagué de la feuille f , $\varepsilon(T, E)$ l'erreur obtenue sur un échantillon E du jeu de données avec l'arbre T et $\text{nombre_feuilles}(T)$ le nombre de feuilles de l'arbre T . Une procédure de cross-validation est souvent utilisée à cette étape pour générer l'échantillon E . D'autres approches peuvent être mises en œuvre pour trouver le sous-arbre optimal mais le principe général reste le même.

Références

- Breiman, L., Friedman, J., Olshen, R., Stone, C., 1984. Classification and Regression Tree, Wadsworth International. California.
- Chauhan, N., 2019. Decision Tree Algorithm — Explained [WWW Document]. Data Sci. URL <https://towardsdatascience.com/decision-tree-algorithm-explained-83beb6e78ef4>

Définition et application

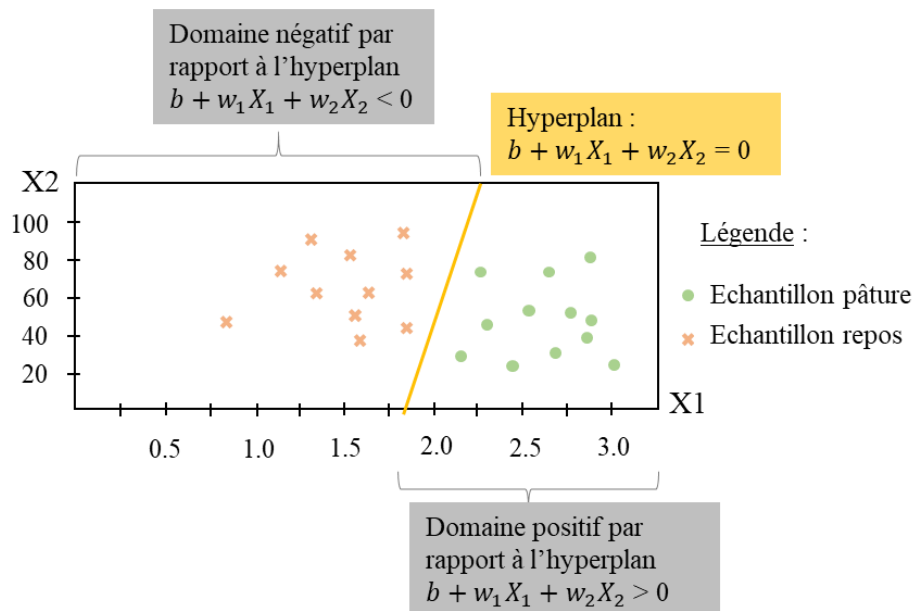
L'algorithme de Support Vector Machine (SVM) est une méthode de classification de *machine learning* développée dans les années 1990 sur la base de la théorie de Vapnik-Tchervonenkis. Son aptitude à travailler avec des données de grandes dimensions, son faible nombre d'hyperparamètres à ajuster et ses très bons résultats ont contribué à l'adoption de cette méthode dans une diversité de domaines.

Principe général

Le principe du SVM est de trouver une surface de décision, appelée *hyperplan*, qui discrimine au mieux les échantillons selon la classe à laquelle ils appartiennent. Supposons un cas simple dans lequel nous disposons de :

- 22 fenêtres de signal (*i.e.* 22 échantillons) : 12 fenêtres associées au comportement de pâturage et 10 autres associées au comportement de repos.
- Deux variables quantitatives : la moyenne de l'OBDA ci-après nommée X1 et la moyenne de la série *roll* ci-après nommée X2.

Supposons que la distribution des échantillons selon (X1, X2) soit la suivante :



L'algorithme SVM consiste à identifier l'hyperplan qui discrimine au mieux les deux types d'échantillons, représenté ici par la droite en jaune. L'hyperplan peut être défini par ses coordonnées cartésiennes selon l'équation suivante :

$$b + w_1X_1 + w_2X_2 = 0$$

Avec X_1 et X_2 les deux variables du jeu de données, w_1 et w_2 les poids associés à chacune des variables et b une constante. A partir de cet hyperplan, deux domaines peuvent être déterminés :

- Le domaine positif par rapport à l'hyperplan, définit par l'équation

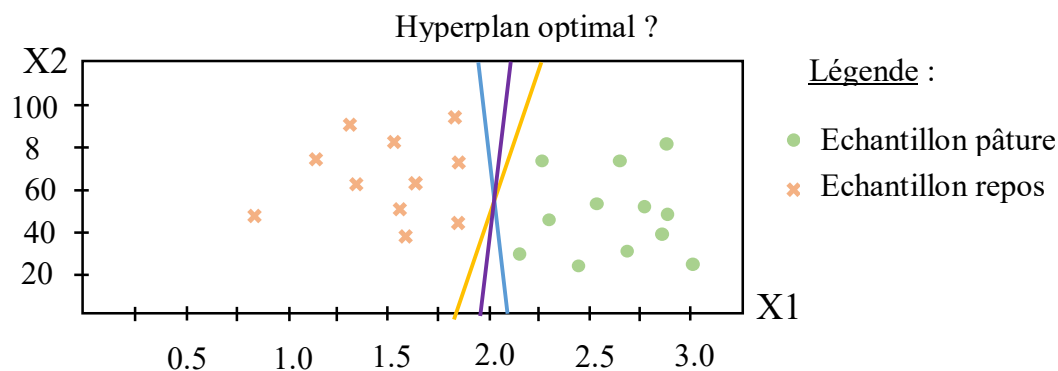
$$b + w_1X_1 + w_2X_2 > 0$$
- Le domaine négatif par rapport à l'hyperplan, définit par l'équation

$$b + w_1X_1 + w_2X_2 < 0$$

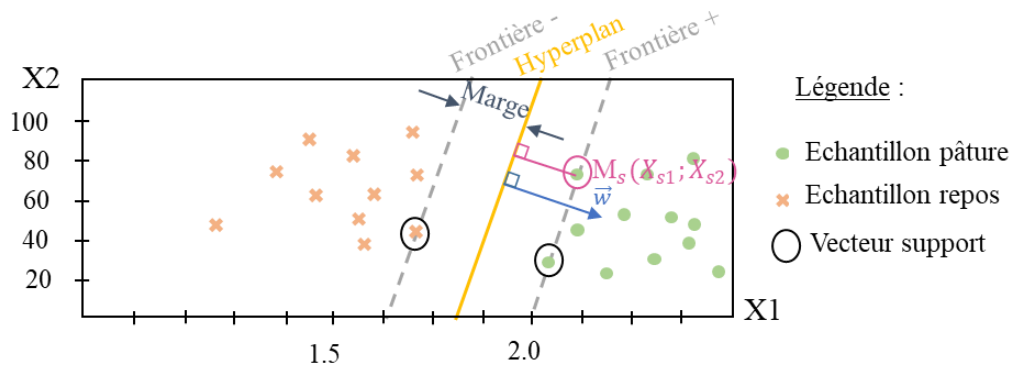
Par la suite, tous les échantillons situés au-dessus de l'hyperplan seront prédits en comportement de pâturage (domaine positif) et inversement, les échantillons situés en dessous de l'hyperplan seront prédits en comportement de repos (domaine négatif). A ce propos, si on appelle y_i le comportement associé à l'échantillon x_i et qui prend la valeur -1 lorsque le comportement est « repos » et +1 lorsque le comportement est « pâture », alors l'échantillon sera bien classé uniquement si $y_i(b + w_1X_{i1} + w_2X_{i2}) > 0$.

Identification de l'hyperplan optimal

Le problème sous-jacent repose sur l'identification de l'hyperplan optimal. Comme illustré ci-après, il existe en réalité une infinité d'hyperplans possibles pour discriminer les échantillons. Il convient donc d'identifier celui qui est le plus discriminant possible.



Dans ce contexte, l'hyperplan optimal est trouvé par la méthode de *maximisation de la marge*. Considérons l'illustration ci-après. L'hyperplan est représenté par la droite en jaune. On appelle la *marge* la plus courte distance qui sépare les échantillons les plus proches de l'hyperplan, aussi appelés *vecteurs supports*.



Etape 1 : Expression de la marge

Soit M_s un échantillon du jeu de données décrit précédemment. M_s est défini par ses variables $X_{s,1}$ et $X_{s,2}$ et associé à la classe y_s qui vaut -1 si le comportement est « repos » ou 1 si le comportement est « pâture ». Supposons que M_s soit un vecteur support potentiel. Soit H l'hyperplan défini par l'équation $b + w_1X_1 + w_2X_2 = 0$. Connaissant l'équation du plan, on peut définir un vecteur normal au plan noté \vec{w} de coordonnées $(w_1 ; w_2)$. La marge étant définie comme la distance la plus courte entre l'échantillon M_s et l'hyperplan H, elle correspond nécessairement à la projection orthogonale de M_s sur ce plan. Le problème revient donc à calculer la distance associée à la projection orthogonale d'un point de coordonnées connues sur un plan défini par son équation cartésienne. On a donc :

$$marge = d(M_s, H) = \frac{|b + w_1X_{s1} + w_2X_{s2}|}{\sqrt{w_1^2 + w_2^2}} \quad (eq. 1)$$

Etape 2 : Maximisation de la marge

La meilleure discrimination entre les deux classes d'échantillons correspond nécessairement à celle qui maximise la marge. L'hyperplan optimal est donc celui pour lequel la marge est maximale.

En pratique, il existe une infinité de solutions b, w_1 et w_2 . Afin de simplifier l'optimisation du problème, on choisit de normaliser b, w_1 et w_2 de manière à avoir $|b + w_1X_{s1} + w_2X_{s2}| = 1$, avec M_s un vecteur support. Les frontières positives et négatives (cf. figure précédente) sont donc définies par les équations de plan suivantes :

$$\begin{cases} b + w_1X_{s1}^+ + w_2X_{s2}^+ = 1 \quad (eq. 2) \\ b + w_1X_{s1}^- + w_2X_{s2}^- = -1 \quad (eq. 3) \end{cases}$$

Avec $M_s^+(X_{s1}^+, X_{s2}^+)$ un vecteur support appartenant à la frontière positive et $M_s^-(X_{s1}^-, X_{s2}^-)$ un vecteur support appartenant à la frontière négative.

En considérant la condition de normalisation, le problème revient à trouver les coefficients b, w_1 et w_2 tels que :

- (1) La condition $y_i (b + w_1 X_{i1} + w_2 X_{i2}) \geq 1$ soit satisfaite pour tout échantillon M_i du jeu de données.

Explication (cf figure précédente) :

Soit M_i un échantillon quelconque du jeu de données associé à la classe y_i .

- Si $y_i = 1$, alors l'échantillon est bien classé s'il est situé à droite de la frontière positive définie par l'équation $b + w_1 X_{s1}^+ + w_2 X_{s2}^+ = 1$ (eq. 2).
 \Rightarrow On a donc $(b + w_1 X_{i1} + w_2 X_{i2}) \geq 1 \Rightarrow y_i (b + w_1 X_{i1} + w_2 X_{i2}) \geq 1$
- Si $y_i = -1$, alors l'échantillon est bien classé s'il est situé à gauche de la frontière négative définie par l'équation $b + w_1 X_{s1}^- + w_2 X_{s2}^- = -1$ (eq. 3).
 \Rightarrow On a donc $(b + w_1 X_{i1} + w_2 X_{i2}) \leq -1 \Rightarrow y_i (b + w_1 X_{i1} + w_2 X_{i2}) \geq 1$

Les coefficients recherchés b, w_1 et w_2 doivent donc répondre à la condition $y_i (b + w_1 X_{i1} + w_2 X_{i2}) \geq 1$ pour tout échantillon M_i du jeu de données.

- (2) L'expression $\sqrt{w_1^2 + w_2^2}$ soit minimale

Explication :

En considérant la condition de normalisation $|b + w_1 X_{s1} + w_2 X_{s2}| = 1$, on a :

$$\text{marge} = \frac{1}{\sqrt{w_1^2 + w_2^2}} \text{ d'après (eq. 1)}$$

Maximiser la marge revient donc à minimiser $\sqrt{w_1^2 + w_2^2}$

On se retrouve donc à devoir minimiser $\sqrt{w_1^2 + w_2^2}$ sous la contrainte $y_s (b + w_1 X_{s1} + w_2 X_{s2}) \geq 1$.

Ce problème est résolu par la méthode des multiplicateurs de Lagrange.

Remarque

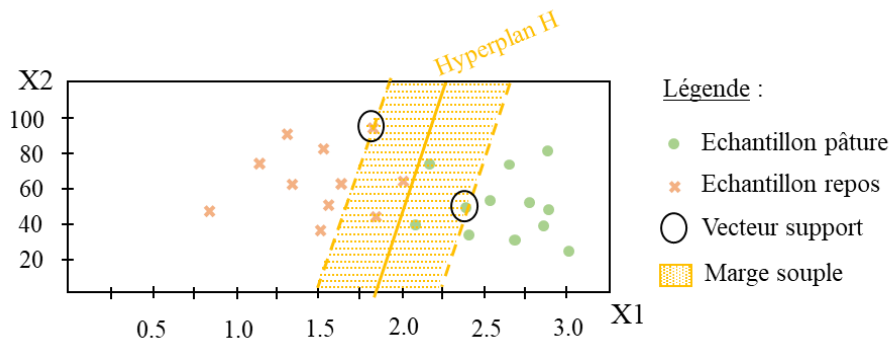
Dans un souci de simplification, toute l'explication a été faite en considérant un jeu de données de deux variables. Le problème est bien-sûr généralisable avec m variables $\gg 2$, ce qui revient à chercher l'hyperplan suivant :

$$b + w_1 X_1 + w_2 X_2 + \dots + w_m X_m = 0 \Rightarrow b + \sum_{i=1}^m w_i X_i = 0. \text{ Trouver l'hyperplan optimal}$$

revient à minimiser $\sqrt{\sum_{i=1}^m w_i^2}$ sous la contrainte $y_s (b + \sum_{i=1}^m w_i X_{si}) \geq 1$.

Notion de marge faible

Dans le cas précédent, nous avons implicitement supposé qu'aucun échantillon ne devait être compris dans la marge. Une telle situation peut néanmoins conduire à une surface de décision trop spécifique du jeu de données d'apprentissage, en particulier si celui-ci comprend des échantillons atypiques. Pour éviter ce problème de *sur-ajustement*, un certain nombre d'échantillons inclus dans la marge peuvent être tolérés, comme illustré ci-après. On parle alors de *marge souple*. Un *paramètre de régularisation* noté C est dans ce cas utilisé afin de trouver le compromis entre le nombre de mauvais classements et la largeur de la marge.



Cas des séparateurs non linéaires

Jusqu'ici, nous avons implicitement fait l'hypothèse que les échantillons pouvaient être discriminés par un séparateur linéaire, ce qui est en pratique rarement le cas. Afin de remédier à ce problème, l'algorithme SVM utilise une *fonction de noyau* (« *kernel trick* ») qui permet de reconsidérer le problème en introduisant de nouvelles dimensions, avec pour objectif de trouver un séparateur linéaire dans ce nouvel espace. En pratique, cela revient à appliquer aux variables d'entrée X une transformation non-linéaire notée Φ . L'espace obtenu $\Phi(X)$ est appelé *espace de redescription*. L'objectif est alors de trouver l'hyperplan optimal dans l'espace de redescription de la même façon que précédemment.

En pratique, deux fonctions de noyau sont généralement utilisées :

Le *noyau polynomial* : $\Phi(X_1, X_2) = (a + \sum_{i=1}^N X_{i1}X_{i2})^b$ avec N le nombre d'échantillons, (X_1, X_2) les deux variables, b le degré du polynôme et a une constante.

La fonction de *base radiale* : $\Phi(X_1, X_2) = \exp(-\gamma \|X_1 - X_2\|^2)$ avec $\|X_1 - X_2\|$ la distance euclidienne entre les variables X_1 et X_2 et γ un paramètre de contrôle du sur-ajustement.

Références

Yadav, A., 2018. Support Vector Machines (SVM) [WWW Document]. Data Sci. URL <https://towardsdatascience.com/support-vector-machines-svm-c9ef22815589>

Annexe VIII. Principe de l'algorithme de forêt aléatoire pour la classification

Définition et application

L'algorithme de forêt aléatoire a été proposée en 2001 par Léo Breiman et Adèle Cutler. Cet algorithme est une méthode de classification supervisée ou de régression de *machine learning* qui appartient à la technique de *bagging*. Seule la méthode de classification supervisée est présentée ici.

Principe général

L'algorithme de forêt aléatoire consiste à créer un ensemble d'*arbres de décision* de façon indépendante à partir d'un sous-ensemble d'échantillons choisi de manière aléatoire. A chaque nœud de l'arbre, un certain nombre de variables est choisi aléatoirement. De cette manière, une multitude d'arbres différents peuvent être construits. Une fois la forêt obtenue, la classe associée à un nouvel échantillon est prédite par vote majoritaire.

Algorithme

On appelle $t = 1, 2, \dots, T$ le numéro de l'itération. Considérons un jeu de données constitué de n échantillons et de p variables.

Etape 1 : construction des arbres

Soit $t = 1$.

(A) Création d'un nouveau jeu de données *via* la technique du *bootstrapping*

Le *bootstrap* consiste à tirer aléatoirement n échantillons avec remise. Comme illustré ci-après, des échantillons peuvent donc être tirés plusieurs fois (échantillons en gras et en noir) tandis que d'autres peuvent ne jamais avoir été tirés (échantillons en gras et en gris). On appelle les échantillons non tirés les échantillons « *Out Of Bag* », notés OOB.

Jeu de données initial			
OBDA	Roll	Entropie	Comportement
2.6	72	0.5	Pâture
2.4	79	0.7	Pâture
1.6	74	0.1	Repos
3.0	69	0.6	Pâture
1.2	75	0.05	Repos
2.8	74	0.4	Pâture


Jeu de données utilisé à l'itération $t = 1$			
OBDA	Roll	Entropie	Comportement
2.6	72	0.5	Pâture
2.4	79	0.7	Pâture
1.6	74	0.1	Repos
2.6	72	0.5	Pâture
1.2	75	0.05	Repos
1.2	75	0.05	Repos

Jeu de données OOB de l'itération $t = 1$			
OBDA	Roll	Entropie	Comportement
3.0	69	0.6	Pâture
2.8	74	0.4	Pâture

(B) Construction d'un arbre de décision sur le jeu de données bootstrappé avec m variables à chaque nœud

Le premier nœud comprend systématiquement tous les échantillons du jeu de données. Afin d'établir la première *règle de décision* ou *condition* qui divise ce nœud parent en deux nœuds enfants, m variables sont tirées aléatoirement dans le jeu de données, avec $m < p$. Par défaut, $m = \sqrt{p}$. La règle de décision est alors construite uniquement sur la base des m variables. La condition retenue correspond à celle qui discrimine au mieux les échantillons, *i.e.* qui minimise l'index de Gini (cf Annexe E).

Supposons qu'on pose $m = 2$ et que les deux variables tirées aléatoirement pour le premier nœud soit la moyenne de l'OBDA et de la série *roll*. On cherche alors la règle de décision basée sur l'une de ces deux variables qui minimise l'index de Gini. On obtient ainsi la première séparation de l'arbre.



Au nœud suivant, m variables sont de nouveau tirées aléatoirement. La seconde règle de décision est construite de la même manière, et ainsi de suite jusqu'à convergence du critère de complexité (cf Annexe VI).

Lorsque l'arbre de l'itération $t = 1$ est terminé, l'algorithme réitère les étapes (A) et (B) pour $t = 2$, et ainsi de suite jusqu'à ce que $t = T$.


Etape 2 : évaluation de la classification de chacun des arbres

Les performances de classification de chacun des arbres, et par suite, de la forêt, sont calculées par l'algorithme. Pour cela, les échantillons OOB issus de l'itération t sont utilisés pour évaluer la prédiction obtenue avec l'arbre créé à cette même itération. Ces échantillons n'ayant pas servi à construire l'arbre, cette approche garantit une évaluation robuste de chacun des classifieurs. L'erreur de classification est ainsi calculée pour chacun des arbres. L'erreur moyenne de la forêt aléatoire correspond à la moyenne des erreurs obtenues.

Remarque : L'erreur de la forêt est aussi utilisée pour rechercher le nombre optimal d'arbres T et de variables m à tirer à chaque nœud. Les paramètres T et m retenus sont ceux qui minimisent l'erreur de la forêt.

Etape 3 : prédiction d'un nouvel échantillon

La prédiction de la classe associée à un nouvel échantillon est réalisée par vote majoritaire. Chacun des classifieurs réalise ainsi sa propre prédiction. La classe retenue est celle qui aura obtenu le plus de voix sur l'ensemble des classifieurs.



Références


Breiman, L., 2001. Random Forests. Mach. Learn. 45, 5–32.

Définition et applications

AdaBoost (*adaptive boosting*) est une méthode ensembliste de *machine learning* utilisée pour des problèmes de classification supervisée. Il s'agit d'un méta-algorithme de *boosting* qui utilise généralement un arbre de décision comme *classifieur faible*.


Principe de l'algorithme

L'algorithme AdaBoost consiste à *booster* successivement les performances de *classifieurs faibles* en donnant plus de poids aux échantillons mal classés par le classifieur courant. La décision finale prise par le *classifieur fort*, *i.e.*, la classe qui sera prédite en sortie de l'algorithme pour un échantillon donné, prendra en compte toutes les sorties des classifieurs faibles avec une pondération qui dépendra de leurs performances respectives.




Définition du jeu de données

Considérons un jeu de données constitué de 24 échantillons (12 échantillons associés au comportement de « repos », 12 échantillons associés au comportement « pâture »), et de deux variables, la moyenne de l'OBDA et la moyenne de la série *roll*, notées respectivement X_{i1} et X_{i2} pour toute fenêtre i du jeu de données. On appelle y_i le comportement associé à chaque fenêtre i . Par la suite, on considérera que y_i prend la valeur -1 lorsqu'il s'agit du comportement « repos » et la valeur $+1$ lorsqu'il s'agit du comportement « pâture ». L'objectif est de trouver la meilleure discrimination possible des échantillons. La distribution des 24 échantillons sur X_1 et X_2 est représentée ci-après.



Etape 1 : Identification du premier classifieur faible

Soit T le nombre maximum d'itérations et $t = 1$ la première itération de l'algorithme. L'algorithme AdaBoost commence par identifier un premier *classifieur faible* noté $h_{t=1}$, c'est-à-dire un *arbre de décision constitué uniquement de deux feuilles* (« *stump* ») qui divise le jeu de données en groupes les plus homogènes possibles. Pour cette première étape, on considère que chaque échantillon a rigoureusement la même importance, *i.e.* le même *poids*, dans le calcul de l'erreur de classification. Le classifieur $h_{t=1}$ correspond à la droite en pointillé sur la figure suivante :



D'un point de vue algorithmique, cela revient à trouver $h_{t=1}$ qui minimise l'erreur de classification notée $\varepsilon_{t=1}$. Le classifieur $h_{t=1}$ est donc défini de la manière suivante :

$$h_{t=1} = \underset{h}{\operatorname{argmin}}(\varepsilon_{t=1})$$

$$\text{avec } \varepsilon_{t=1} = \sum_{i=1}^n w_{t=1}(i) \underbrace{[y_i \neq h_{t=1}(X_{i1}, X_{i2})]}$$

Evènement qui vaut :

$$\left\{ \begin{array}{l} 1 \text{ si le comportement obtenu avec } h_{t=1} \text{ pour l'échantillon } i \text{ à} \\ \text{partir des variables } (X_{i1}, X_{i2}) \text{ diffère du comportement observé } y_i \\ 0 \text{ sinon} \end{array} \right.$$

avec $w_{t=1}(i) = \frac{1}{n}$ le poids affecté à tout échantillon i du jeu de données à $t = 1$.

Remarque : Par définition, un classifieur faible doit résulter sur une erreur de classification strictement inférieure à celle qui aurait été obtenue par hasard ($\varepsilon_t < 0.5$ dans ce contexte). L'algorithme s'arrêtera si aucun classifieur satisfaisant cette condition n'a pu être trouvé.

Etape 2 : Calcul et mise à jour des poids

A l'issue de la première classification par $h_{t=1}$, l'algorithme va d'abord :

- Calculer le poids du classifieur $h_{t=1}$, noté $\alpha_{t=1}$:

$$\alpha_{t=1} = \frac{1}{2} \log \left(\frac{1 - \varepsilon_{t=1}}{\varepsilon_{t=1}} \right)$$

⇒ $\alpha_{t=1}$ sera d'autant plus élevé que le classifieur est performant, *i.e.*, minimise l'erreur ε_t .

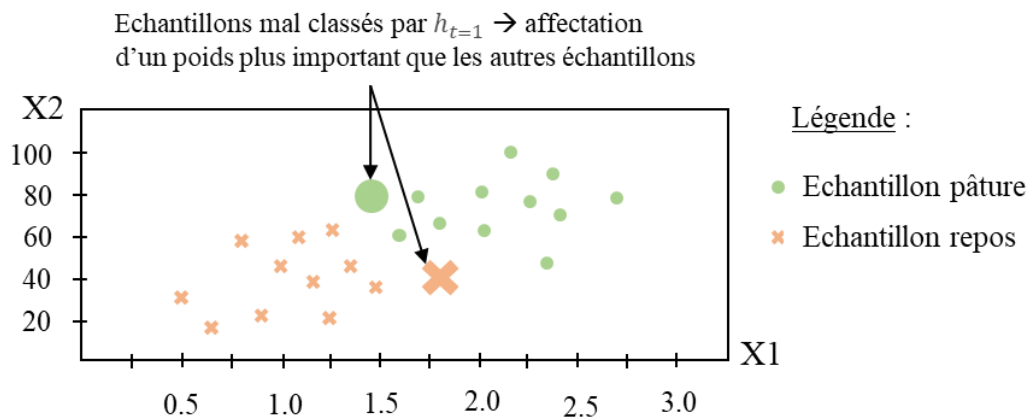
- Mettre à jour le poids de chaque échantillon i du jeu de données, noté $w_{t=2}(i)$ pour la deuxième itération :

$$w_{t=2}(i) = \frac{w_{t=1}(i) e^{-\alpha_{t=1} y_i h_{t=1}(X_{i1}, X_{i2})}}{Z_{t=1}}$$

Avec $Z_{t=1}$ un facteur de normalisation qui garantit que la somme des $w_{t=2}(i)$ pour tout i soit égale à 1 :

$$Z_{t=1} = 2 \sqrt{\varepsilon_{t=1} (1 - \varepsilon_{t=1})}$$

⇒ Les poids $w_{t=2}$ les plus élevés seront affectés aux échantillons qui sont mal classés par le classifieur $h_{t=1}$, comme illustré ci-dessous :



⇒ Ces échantillons auront donc une contribution plus importante dans le calcul de l'erreur de classification $\varepsilon_{t=2}$:


$$\varepsilon_{t=2} = \sum_{i=1}^n \underbrace{w_{t=2}(i)}_{w_{t=2}(i) > \frac{1}{n} \text{ pour tout } i \text{ tel que } [y_i \neq h_{t=1}(X_{i1}, X_{i2})]} [y_i \neq h_{t=2}(X_{i1}, X_{i2})]$$

Focus : explication intuitive du poids du classifieur et du poids des échantillons

- Revenons d'abord sur la définition du poids du classifieur $h_{t=1}$ noté $\alpha_{t=1}$:

$$\alpha_{t=1} = \frac{1}{2} \log \left(\frac{1-\varepsilon_{t=1}}{\varepsilon_{t=1}} \right)$$

La représentation graphique de la fonction $f(\varepsilon) = \log \left(\frac{1-\varepsilon_{t=1}}{\varepsilon_{t=1}} \right)$ est la suivante:



⇒ D'après la définition de $\alpha_{t=1}$, plus le classifieur $h_{t=1}$ aura une erreur de classification faible, plus le poids qui lui sera affecté sera élevé.

- Considérons maintenant la définition du poids $w_{t=2}(i)$ affecté à chaque échantillon i

$$w_{t=2}(i) = \frac{w_{t=1}(i) e^{-\alpha_{t=1} y_i h_{t=1}(X_{i1}, X_{i2})}}{Z_{t=1}}$$


⇒ Deux cas possibles peuvent se présenter pour chacun des échantillons i :

Soit l'échantillon i est bien classé, auquel cas

$$y_i h_{t=1}(X_{i1}, X_{i2}) = 1$$

Dans ce cas, la représentation graphique de

$$f(\alpha_{t=1}) = e^{-\alpha_{t=1} y_i h_{t=1}(X_{i1}, X_{i2})}$$
 est :




⇒ Si l'échantillon est bien classé, le nouveau poids pour cet échantillon sera d'autant plus faible que le classifieur $h_{t=1}$ est performant (i.e. que $\alpha_{t=1}$ est élevé).

Soit l'échantillon i est mal classé, auquel cas

$$y_i h_{t=1}(X_{i1}, X_{i2}) = -1$$

Dans ce cas, la représentation graphique de


$$f(\alpha_{t=1}) = e^{-\alpha_{t=1} y_i h_{t=1}(X_{i1}, X_{i2})}$$
 est :



⇒ Si l'échantillon est mal classé, le nouveau poids pour cet échantillon sera d'autant plus fort que le classifieur $h_{t=1}$ est performant (i.e. que $\alpha_{t=1}$ est élevé).

Etape 3 : Identification du second classifieur faible

L'algorithme AdaBoost va ensuite identifier à l'itération $t = 2$ un second classifieur faible noté $h_{t=2}$ qui minimise l'erreur de classification $\varepsilon_{t=2}$. Comme expliqué précédemment, les erreurs commises par $h_{t=1}$ sont prises en compte dans le calcul de $\varepsilon_{t=2}$ de manière à améliorer la classification des échantillons mal classés par $h_{t=1}$. Le classifieur $h_{t=2}$ correspondrait au classifieur en pointillés dans la figure ci-après.



Les étapes 2 et 3 sont reconduites de façon itérative jusqu'à ce que $t = T$, avec T le nombre maximal d'itérations.

Etape 4 : Définition du classifieur fort

A l'issue des T itérations, le *classifieur fort* obtenu, noté H_{X_1, X_2} , est le suivant :

$$H_{X_1, X_2} = \text{signe}(\underbrace{\alpha_{t=1} h_{t=1}(X_1, X_2)}_{\text{Poids associé au classifieur faible } h_{t=1}} + \alpha_{t=2} h_{t=2}(X_1, X_2) + \dots + \alpha_{t=T} h_{t=T}(X_1, X_2))$$

Poids associé au classifieur faible $h_{t=1}$

Afin de prédire le comportement d'un nouvel échantillon i , H_{X_1, X_2} fait donc la somme de chacune des sorties des classifieurs faibles (+ 1 ou - 1), en affectant un poids plus ou moins fort selon la performance du classifieur. Cela revient à réaliser un vote pondéré sur les décisions de chacun des classifieurs faibles. Le classifieur fort H_{X_1, X_2} prédira donc le comportement :

- « Repos » si la somme des décisions est de signe négatif
- « Pâture » si la somme des décisions est de signe positif

Références

Fabien, M., 2019. Boosting and AdaBoost clearly explained [WWW Document]. Data Sci. URL <https://towardsdatascience.com/boosting-and-adaboost-clearly-explained-856e21152d3e>

Annexe X. Principe de l'algorithme de gradient boosting avec arbres de décision et cas particulier de l'eXtreme Gradient Boosting

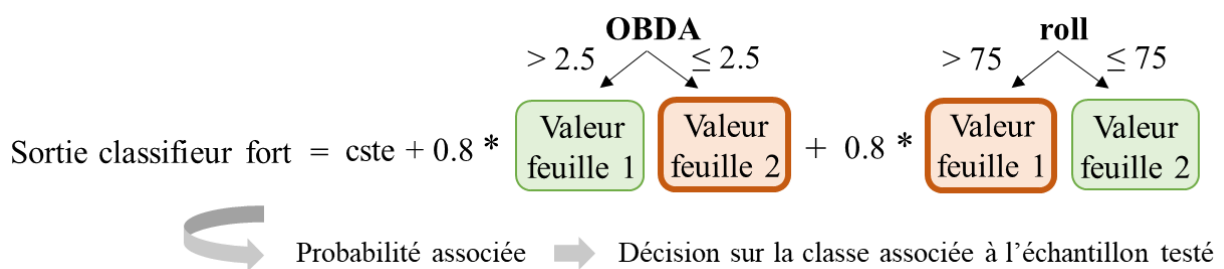
Définition et application

L'algorithme d'*eXtreme Gradient Boosting* (XGB) est un algorithme adapté du *gradient boosting* qui est une méthode ensembliste de *machine learning*. Cet algorithme vise à développer un modèle de classification à partir d'un ensemble de classifieurs faibles comme des arbres de décisions.

Principe général

Le principe de l'algorithme de *gradient boosting* est présenté ci-après. Les principales particularités de XGB seront ensuite énoncées.

L'objectif du *gradient boosting* est de développer un modèle de classification permettant d'obtenir pour chaque échantillon la probabilité qu'il soit affecté à une classe k . L'algorithme de *gradient boosting* consiste à régresser itérativement un ensemble de classifieurs faibles (arbres de décision) sur les résidus obtenus avec l'arbre précédent. La valeur associée à chacune des feuilles est celle qui minimise une fonction de coût spécifique à cet algorithme. Afin de réaliser une prédiction sur un échantillon i , le classifieur fort obtenu prend en compte les sorties de chacun des classifieurs faibles, pondérées par un paramètre d'apprentissage. La probabilité que l'échantillon appartienne à la classe k est déduite à partir de l'ensemble des sorties de chacun des classifieurs faibles.



Algorithme

Définitions

On considère le jeu de données (x_i, y_i) avec $i = 1, 2, \dots, n$ un échantillon du jeu de données, x_i les variables associées et y_i la variable à prédire pour cet échantillon qui peut valoir 0 ou 1.

Exemple : définition du jeu de données

On considère un jeu de données composé de trois fenêtres de signal et de deux variables : la moyenne de l'OBDA et la moyenne du *roll*. Chacun des échantillons i est associé à une variable y_i qui vaut 1 si la fenêtre est associée au comportement « pâture » et 0 sinon.

Nombre d'échantillons associés au comportement « pâture »

Nombre d'échantillons associés au comportement « ne pâture pas »

OBDA	Roll	comportement (y_i)
2.6	72	Pâture ($y_i = 1$)
2.4	79	Pâture ($y_i = 1$)
1.6	74	Ne pâture pas ($y_i = 0$)

Soit p la probabilité que $y_i = 1$. On définit les odds ratio, notés odds, de la façon suivante :

$$odds = \frac{p}{1-p} \Rightarrow p = \frac{e^{\log(odds)}}{1 + e^{\log(odds)}}$$

On pose $F(x_i) = \log(odds)$. On définit alors la fonction de coût notée $L(y_i, F(x_i))$ pour l'échantillon i de la manière suivante :

$$L(y_i, F(x_i)) = -y_i \log(odds) + \log(1 + e^{\log(odds)})$$

On démontre alors que $L(y_i, F(x_i)) = -[y_i \log(p) + (1 - y_i) * \log(1 - p)]$

Remarque : avec la fonction de coût ainsi définie, on retrouve l'expression

$-\log$ (vraisemblance pour l'échantillon i) qui est une fonction couramment utilisée en statistique inférentielle. Le maximum de vraisemblance correspond à la meilleure prédiction possible pour l'échantillon i

Etape 1 : initialisation

La première étape de l'algorithme consiste à initialiser un modèle avec une valeur constante

$Y = \log(odds)$ tel que $F_0(x) = \operatorname{argmin}_Y \sum_{i=1}^n L(y_i, Y)$



Revient à trouver la valeur de Y pour laquelle

$\sum_{i=1}^n L(y_i, Y)$ est minimale, avec $Y = \log(odds)$

➔ Trouver la valeur Y telle que la fonction $\sum_{i=1}^n L(y_i, Y)$ soit minimale revient à trouver la valeur de Y pour laquelle la dérivée s'annule.

On calcule donc la dérivée de la somme de la fonction de coût $\sum_{i=1}^n L(y_i, Y)$ en fonction de $Y = \log(odds)$:

$$\begin{aligned} & \frac{d}{d \log(odds)} \left(\sum_{i=1}^n L(y_i, Y) \right) \quad \text{On remplace par la définition de } L(y_i, Y) \\ &= \frac{d}{d \log(odds)} \left(\sum_{i=1}^n [-y_i \log(odds) + \log(1 + e^{\log(odds)})] \right) \\ &= \sum_{i=1}^n \left[-y_i + \frac{e^{\log(odds)}}{1 + e^{\log(odds)}} \right] \quad (*) \\ &= \sum_{i=1}^n [-y_i + p] \quad \text{Définition de } p \text{ en fonction de odds} \end{aligned}$$

➔ La première étape de l'algorithme consiste donc à trouver la valeur $Y = \log(odds)$ pour laquelle $\sum_{i=1}^n [-y_i + p] = 0$

Exemple : initialisation du modèle avec une constante

Considérons le jeu de données défini précédemment. Trouver la valeur constante $F_0(x) = Y$ revient à résoudre l'équation suivante :

$$\begin{aligned} \sum_{i=1}^3 [-y_i + p] &= 0 \\ \Leftrightarrow -y_1 + p - y_2 + p - y_3 + p &= 0 \\ \Leftrightarrow -1 + p - 1 + p - 0 + p &= 0 \\ \Leftrightarrow p = 2/3 \approx 0.67 \end{aligned}$$

En repassant par l'expression de p en fonction des odds ratio, on en déduit alors la constante Y :

$$Y = \log(odds) = \log\left(\frac{p}{1-p}\right) = \log\left(\frac{2/3}{1-2/3}\right) = \log\left(\frac{2}{1}\right) \approx 0.69$$

➔ Le modèle est donc initialisé avec la valeur 0.69. En d'autres termes, nous venons de créer un arbre composé d'une seule feuille qui prédit que le logarithme du odds ratio associé à l'évènement $y_i = 1$ (= le comportement de la fenêtre i est « pâture ») est de 0.69 pour toute fenêtre i .

➔ $F_0(x) = Y =$ 0.69

Etape 2 : cœur de l'algorithme

L'étape 2 est constituée de 4 étapes que nous appellerons (A), (B), (C) et (D).

Soit m le numéro de l'itération. Pour $m = 1, 2, \dots, M$:

$$(A) \text{ Calculer } r_{im} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x)=F_{m-1}(x)} \text{ pour } i = 1, 2, \dots, n$$

Calcul de la dérivée uniquement avec les $F(x_i)$ obtenus à l'étape précédente

Dérivée de la fonction de coût par rapport à $F(x_i) = \log(odds)$ pour chaque échantillon i

$$\text{On a donc pour tout échantillon } i \text{ et à l'itération } m : r_{im} = - \frac{d}{d \log(odds)} \left(L(y_i, F(x_i)) \right)$$

$$\Rightarrow r_{im} = - \left[-y_i + \frac{e^{\log(odds)}}{1 + e^{\log(odds)}} \right] \text{ d'après } (*)$$

$$\Rightarrow r_{im} = -[-y_i + p]$$

$$\Rightarrow r_{im} = [y_i - p] \quad (**) \text{ Pseudo résidus}$$

Remarque : Analogie avec les moindres carrés en régression linéaire où

Résidu i = valeur observée i - valeur prédite i

➔ Calculer r_{im} revient donc à calculer les pseudos résidus de chaque échantillon i pour l'itération m

Exemple : Calcul des r_{im} (étape 2 - (A))

Considérons la première itération $m = 1$. Calculons r_{i1} pour chaque échantillon i .

OBDA	Roll	comportement (y_i)	Pseudo résidus r_{i1}
2.6	72	Pâturer ($y_i = 1$)	0.33
2.4	79	Pâturer ($y_i = 1$)	0.33
1.6	74	Ne pâturer pas ($y_i = 0$)	-0.67

$$r_{11} = y_1 - p = 1 - 0.67 = 0.33$$

➔ Calculée à l'exemple précédent

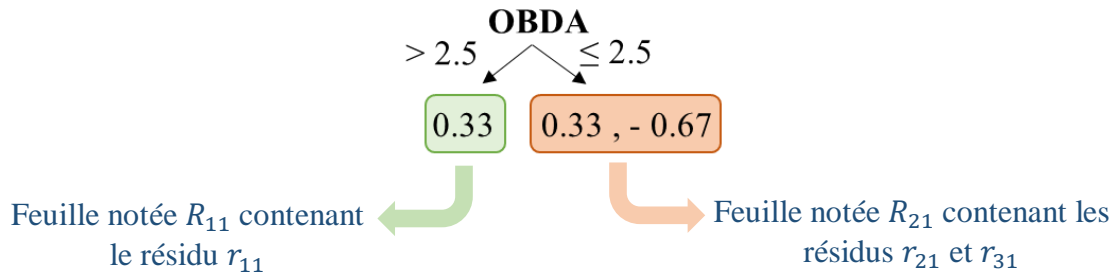
$$r_{21} = y_2 - p = 1 - 0.67 = 0.33$$

$$r_{31} = y_3 - p = 0 - 0.67 = -0.67$$

(B) Ajuster un arbre de régression aux pseudo-résidus r_{im} et créer des feuilles terminales R_{jm} pour chaque feuille $j = 1, 2, \dots, J_m$

Exemple : Ajuster une arbre de régression aux résidus r_{im} (étape 2 – (B))

A l'itération $m = 1$, on ajuste un arbre aux valeurs r_{im} . L'arbre obtenu est le suivant :



(C) Pour $j = 1, 2, \dots, J_m$ calculer $\Upsilon_{jm} = \operatorname{argmin}_{\Upsilon} \sum_{x_i \in R_{ij}} L(y_i, F_{m-1}(x_i) + \Upsilon)$

Pour chaque feuille R_{jm} de l'arbre créé à l'itération $m \dots$

... on trouve la valeur Υ_{jm} pour cette feuille

Υ_{jm} correspond à la valeur $\Upsilon = \log(\text{odds})$ qui minimise $\sum_{x_i \in R_{ij}} L(y_i, F_{m-1}(x_i) + \Upsilon)$

Seuls les échantillons i qui appartiennent à la feuille R_{ij} sont impliqués dans la somme

Expression de la fonction de coût $L(y_i, X_i)$ avec $X_i = F_{m-1}(x_i) + \Upsilon$

➔ On cherche donc pour chacune des feuilles de l'arbre créé précédemment la valeur Υ qui minimise $\sum_{x_i \in R_{ij}} L(y_i, F_{m-1}(x_i) + \Upsilon)$

En remplaçant par l'expression de la fonction de coût définie précédemment, on a :

$$\sum_{x_i \in R_{ij}} L(y_i, F_{m-1}(x_i) + \Upsilon)$$

$$= \sum_{x_i \in R_{ij}} \left[-y_i * (F_{m-1}(x_i) + \Upsilon) + \log(1 + e^{F_{m-1}(x_i) + \Upsilon}) \right]$$

Trouver le minimum de cette expression en Υ nécessite d'approximer $L(y_i, F_{m-1}(x_i) + \Upsilon)$ avec un polynôme de Taylor du second ordre puis de dériver l'expression obtenue. La valeur Υ recherchée correspond à celle pour laquelle la dérivée s'annule.

A l'issue de cette étape, on démontre que :

$$Y_{jm} = \frac{\sum_{x_i \in R_{ij}} \left[y_i - \frac{e^{\log(odds)}}{1 + e^{\log(odds)}} \right]}{\sum_{x_i \in R_{ij}} p_i * (1 - p_i)}$$

$$Y_{jm} = \frac{\sum_{x_i \in R_{ij}} [y_i - p_i]}{\sum_{x_i \in R_{ij}} p_i * (1 - p_i)}$$

Avec $p_i = p(x_i) =$ probabilité que $y_i = 1$ pour l'échantillon i

$$Y_{jm} = \frac{\sum_{x_i \in R_{ij}} r_{im}}{\sum_{x_i \in R_{ij}} p_i * (1 - p_i)}$$


Définition des pseudo résidus (**)

Calculer la valeur de log(odds) associée à chacune des feuilles R_{jm} revient donc à

calculer $Y_{jm} = \frac{\sum_{x_i \in R_{ij}} r_{im}}{\sum_{x_i \in R_{ij}} p_i * (1 - p_i)}$ pour chacune d'elle.

Exemple : Calculer la valeur de log(odds) de chacune des feuilles de l'arbre (étape 2 - (C))

OBDA	Roll	comportement (y_i)	Pseudo résidus r_{i1}
2.6	72	Pâture ($y_i = 1$)	0.33
2.4	79	Pâture ($y_i = 1$)	0.33
1.6	74	Ne pâture pas ($y_i = 0$)	-0.67




On calcule d'abord la valeur Y_{11} associée à la feuille R_{11} qui ne comprend que l'échantillon 1 :

$$Y_{11} = \frac{r_{11}}{p_1 * (1 - p_1)} = \frac{0.33}{0.67 * (1 - 0.67)} = 1.49$$

On calcule ensuite la valeur Y_{21} associée à la feuille R_{21} qui comprend l'échantillon 2 et l'échantillon 3 :

$$Y_{21} = \frac{r_{21} + r_{31}}{p_2 * (1 - p_2) + p_3 * (1 - p_3)} = \frac{0.33 - 0.67}{0.67 * (1 - 0.67) + 0.67 * (1 - 0.67)} = -0.77$$



Remarque : on avait ici $p_1 = p_2 = p_3 = p$ pour $m = 1$ mais ces probabilités seront modifiées au fur et à mesure des itérations. La mise à jour des probabilités associées à $[y_i = 1]$ pour chacun des échantillons i est réalisée à l'étape D.

(D) Mettre à jour $F_m(x_i) = F_{m-1}(x_i) + v \sum_{j=1}^{J_m} Y_{jm} I(x_i \in R_{jm})$ pour tout échantillon i

Log(odds) obtenu à partir de l'arbre construit à l'itération m pour un échantillon i associé aux variables x_i

Log(odds) obtenu à partir de l'arbre construit à l'itération $m-1$ pour un échantillon i associé aux variables x_i

Paramètre d'apprentissage

Valeur de la feuille R_{jm}

Définition de la fonction identité :

$$I(x_i \in R_{jm}) = 1 \text{ si } x_i \in R_{jm}$$

$$I(x_i \in R_{jm}) = 0 \text{ si } x_i \notin R_{jm}$$

Les probabilités p_i associées à $F_m(x_i)$ sont également calculées et mises à jour.

Les étapes (A), (B), (C) et (D) sont ensuite réitérées jusqu'à ce que $m = M$ ou que les résidus obtenus convergent vers 0.

Exemple : Mettre à jour les log(odds) et probabilités associées à chaque échantillon i à partir de l'arbre créé à l'étape m .

Soit $v = 0.8$. Commençons par calculer $F_1(x_1)$ pour l'échantillon 1.

$$F_1(x_1) = F_0(x_1) + 0.8 * Y_{11} I(x_1 \in R_{11}) + 0.8 * Y_{21} I(x_1 \in R_{21})$$

$$= 1 \text{ car } x_1 \text{ appartient pas à } R_{11} \quad = 0 \text{ car } x_1 \text{ n'appartient pas à } R_{21}$$

$$F_1(x_1) = 0.69 + 0.8 * 1.49$$

$$F_1(x_1) = 1.88$$

De la même manière, on trouve

$$F_1(x_2) = 0.07 \text{ et } F_1(x_3) = 0.07$$

En repassant par les probabilités, on obtient :

$$p_1 = \frac{e^{1.88}}{1 + e^{1.88}} = 0.86$$

$$p_2 = p_3 = \frac{e^{0.07}}{1 + e^{0.07}} = 0.52$$

A l'issue de la première itération, l'échantillon 1 a une probabilité de 0.86 d'être associé

➔ au comportement « pâture ». Les échantillons 2 et 3 ont une probabilité de 0.52 d'être associés au comportement « pâture ».

Etape 3 : obtention du classifieur fort en sortie de l'algorithme

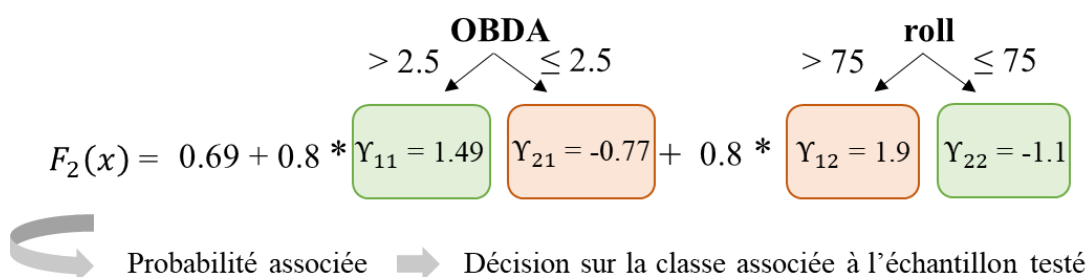
A la fin de l'étape 2, on obtient donc le classifieur fort noté $F_M(x)$:

$$F_M(x) = F_{M-1}(x) + v \sum_{j=1}^{J_m} Y_{jm} I(x_i \in R_{jm})$$

Ce classifieur pourra par la suite être utilisé pour prédire la probabilité qu'un nouvel échantillon i réalise l'évènement $y_i = 1$

Exemple : obtention du classifieur fort

Pour cet exemple constitué de seulement de 3 échantillons et de 2 variables, le classifieur fort obtenu en posant $M = 2$ pourrait être :



Cas particulier de l'eXtreme Gradient Boosting

L'algorithme XGB repose sur l'algorithme de *gradient boosting*. Il consiste donc à régresser itérativement des arbres de décision sur les résidus obtenus avec l'arbre précédent. Les principales différences reposent sur :

- ❖ La construction de l'arbre à chaque étape m . Contrairement au *gradient boosting*, l'arbre construit à chaque étape est unique : il s'agit de celui qui s'ajuste le mieux aux résidus. Pour trouver cet arbre, plusieurs étapes sont réalisées :
 - (1) Une seule partie des échantillons et des variables est sélectionnée aléatoirement à chaque étape m . Ce sous-jeu de données sera celui utilisé pour construire l'arbre de régression à l'itération m . Le ratio de variables et le ratio des échantillons sont fixés par l'utilisateur.
 - (2) Pour chacun des nœuds de l'arbre de régression potentiel, on calcule le score de similarité de la manière suivante :

$$score_{similarite} = \frac{\sum_i \text{résidus}_i^2}{\sum_i [p_i - (1 - p_i)] + \lambda}$$

Avec $\lambda \geq 0$ un paramètre de régularisation fixé par l'utilisateur.

(3) A chaque séparation de l'arbre de régression potentiel, on calcule le gain ci-après :

$$\text{Gain} = \text{score}_{\text{similarite_noeud_gauche}} + \text{score}_{\text{similarite_noeud_droite}} \\ - \text{score}_{\text{similarite_noeud_parent}}$$

(4) Pour chacune des séparations possibles, on retient celle qui maximise le gain.

(5) Une fois l'arbre de régression créé, celui-ci va être élagué afin d'éviter le sur-ajustement de la façon suivante :

- Soit `min_child_weight` un paramètre fixé par l'utilisateur. Toutes les feuilles comprenant un nombre de résidus inférieur au paramètre `min_child_weight` seront supprimées. Par défaut, ce paramètre est fixé à 1.
- Soit γ un paramètre fixé par l'utilisateur. Pour chacune des feuilles, *i.e.*, pour chacun des nœuds terminaux de l'arbre, on calcule $\text{delta} = \text{Gain} - \gamma$. Si $\text{delta} \geq 0$ alors on garde la feuille et la séparation dont elle est issue, sinon on la supprime. Le cas échéant, on réitère l'opération pour les nouvelles feuilles obtenues, etc.

❖ Le calcul des valeurs de log(odds) associées à chaque feuille.

Dans le cas de l'eXtreme Gradient Boosting, on a en effet $Y_{jm} = \frac{\sum_{x_i \in R_{ij}} r_{im}}{\sum_{x_i \in R_{ij}} p_i^*(1-p_i) + \lambda}$

avec λ le paramètre de régularisation introduit précédemment.

- ❖ Le paramètre d'apprentissage noté ν en *gradient boosting* est appelé ϵ et vaut par défaut 0.3.
- ❖ Une parallélisation permet de construire les arbres en même temps ce qui réduit considérablement le temps de calcul.

Références

- Chen, T., He, T., Benesty, M., Khotilovich, V., Tang, Y., Cho, H., Chen, K., Mitchell, R., Cano, I., Zhou, T., Li, M., Xie, J., Lin, M., Geng, Y., Li, Y., 2018. xgboost: Extreme Gradient Boosting.
- Starmer, J., 2020. XGBoost : Part 2: XGBoost Trees For Classification [WWW Document]. URL <https://www.youtube.com/watch?v=8b1JEDvenQU>
- Starmer, J., 2019a. Gradient Boost Part 3: Classification [WWW Document]. URL https://www.youtube.com/results?search_query=statquest+gradient+boost+part+3
- Starmer, J., 2019b. Gradient Boosting Part 4 : Classification Details [WWW Document]. URL <https://www.youtube.com/watch?v=StWY5QWMXCw&t=209s>

Annexe XI. Définition du HMM et principe de l'algorithme de Viterbi

HMM

Le modèle de Markov Caché est un modèle statistique dans lequel le système modélisé est supposé être un processus markovien de paramètres inconnus, *i.e.* un processus dans lequel l'état à l'instant présent ne dépend que de l'état qui précède. Par leur nature statistique, les HMM se situent dans le cadre de la décision bayésienne. Le modèle de Markov Caché constitue ainsi un outil puissant pour induire un concept de nature statistique à partir seulement de séquences d'apprentissage. Pour cette raison, les HMM sont massivement utilisés en reconnaissance de formes ou en traitement automatique du langage.

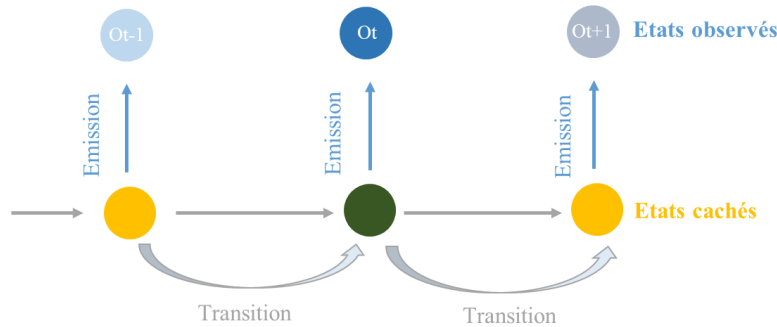
Un modèle HMM est noté $\Lambda = (T, E, \pi)$ et basé sur :

- Des états cachés qui forment l'ensemble $S = \{s_1, s_2, \dots, s_n\}$ où n est le nombre d'états cachés. L'état dans lequel se trouve le HMM à l'instant t est noté q_t ($q_t \in S$).
- m symboles observables dans chaque état. Toutes les observations possibles forment l'ensemble $V = \{v_1, v_2, \dots, v_m\}$. $O_t \in V$ est le symbole observé à l'instant t .
- Une matrice de transition entre états notée T et définie de la manière suivante :
 $T(i, j) = P(q_{t+1} = s_j | q_t = s_i) \forall i, j \in \{1, \dots, n\}$ et $\forall t \in \{1, \dots, T\}$ avec :
 $T(i, j) > 0 \forall i, j$ et $\sum_{j=1}^n T(i, j) = 1$
- Une matrice de probabilité d'observations associées à chacun des états, appelée matrice d'émission et notée E . Cette matrice est définie de la manière suivante :
 $E(j, k) = P(O_t = v_k | q_t = s_j) \forall j \in \{1, \dots, n\}$ et $\forall k \in \{1, \dots, m\}$ avec :
 $E(j, k) > 0$ et $\sum_{k=1}^m E(j, k) = 1$
- Un vecteur de probabilités initiales π : $\pi = \{\pi_1, \pi_2, \dots, \pi_n\}$ où pour chacun des états i , π_i est la probabilité que l'état initial du HMM soit l'état i :
 $\pi_i = P(q_1 = s_i) \forall i \in \{1, \dots, n\}$ with $\pi_i > 0 \forall i$ and $\sum_{i=1}^n \pi_i = 1$

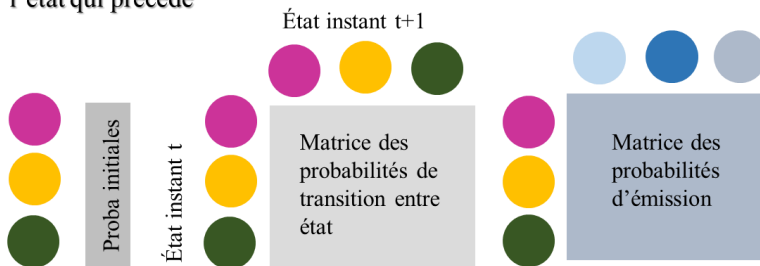
Remarque : Les paramètres (T, E, π) pour une séquence d'observations donnée peuvent être trouvés :

- Soit de façon empirique.
- Soit *via* un apprentissage basé sur l'algorithme de Baum-Welch. Dans ce cas, l'objectif est de trouver les paramètres (T, E, π) qui maximisent la probabilité d'une séquence d'observations $O = \{O_1, O_2, \dots, O_T\}$.

Modèle de Markov caché (HMM)



Processus stochastique markovien : processus aléatoire qui peut changer d'état s_i aux instants t_i et dont l'état à chaque instant ne dépend que de l'état qui précède



Algorithme de Viterbi

L'algorithme de Viterbi est utilisé pour trouver la meilleure suite d'états ayant généré les observations à partir d'un HMM dont les paramètres (T, E, π) sont connus. Trouver le meilleur chemin correspondant à la séquence d'observation revient à trouver la meilleure suite d'états Q connaissant Λ qui maximise la probabilité $P(Q, O | \Lambda)$. Afin de trouver $Q = (q_1, q_2, \dots, q_T)$ pour une séquence d'observations $O = (O_1, O_2, \dots, O_T)$, on définit la variable intermédiaire $\delta_t(i)$ comme la probabilité du meilleur chemin amenant à l'état s_i à l'instant t , en étant guidé par les t premières observations : $\delta_t(i) = \text{Max}_{q_1, q_2, \dots, q_{t-1}} P(q_1, q_2, \dots, q_t = s_i, O_1, O_2, \dots, O_t | \Lambda)$

Par récurrence, on calcule :

$$\delta_{t+1}(j) = [\text{Max}_i \delta_t(i) \mathbf{a}_{ij}] \mathbf{b}_j(O_{t+1})$$

Probabilité de transition : probabilité de passer de l'état s_i à l'instant t à l'état s_j à l'instant $t + 1$
Probabilité d'émission : probabilité d'observer O_{t+1} en supposant qu'on est à l'état s_j à l'instant $t + 1$

en gardant trace, lors du calcul, de la suite d'états qui donne le chemin le plus probable amenant à l'état s_i à t dans un tableau ψ . L'algorithme de Viterbi permet de formaliser cette récurrence. Il fournit en sortie la meilleure suite d'états ayant conduit à la séquence observée avec la probabilité d'émission associée.

Références

Cornuéjols, A., 2019. L'apprentissage de modèles de Markov cachés. Master Informatique et Systèmes Intelligents- AgroParisTech, Paris, France.