



HAL
open science

Suivi non destructif de l'indice de nutrition azotée par proxi- et télédétection en vue d'un pilotage dynamique et spatialisé de la fertilisation azotée du blé tendre

Marie-Astrid Bouchard

► **To cite this version:**

Marie-Astrid Bouchard. Suivi non destructif de l'indice de nutrition azotée par proxi- et télédétection en vue d'un pilotage dynamique et spatialisé de la fertilisation azotée du blé tendre. Sciences agricoles. Université de Lille, 2022. Français. NNT : 2022ULILR011 . tel-04051502

HAL Id: tel-04051502

<https://theses.hal.science/tel-04051502v1>

Submitted on 30 Mar 2023

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

Pour l'obtention du grade de

DOCTEUR DE L'UNIVERSITÉ DE LILLE

Ecole doctorale – 104 Sciences de la Matière, du Rayonnement et de l'Environnement

Discipline : Sciences agronomiques et écologiques

UMR-Transfrontalière n°1158 BioEcoAgro –JUNIA

Par Marie-Astrid Bouchard

Soutenue publiquement à Lille, le 29 mars 2022

Suivi non destructif de l'indice de nutrition azotée par proxi-
et télédétection en vue d'un pilotage dynamique et
spatialisé de la fertilisation azotée du blé tendre

Composition du jury :

M. Benoît MERCATORIS, Professeur, Gembloux Agro-Bio Tech,
Mme Christelle GEE, Professeure, Institut Agro Dijon,
Mme Marie-Christine VAN LABEKE, Professeure, Ghent University,
Mme Stephanie DELALIEUX, Docteure, VITO Remote Sensing,
M. Bertrand VANDOORNE, Enseignant-chercheur, JUNIA,
M. Herinaina A. L. ANDRIAMANDROSO, Enseignant-chercheur, JUNIA,
M. Christophe WATERLOT, Professeur, JUNIA,
M. Ali SIAH, Professeur, JUNIA,

Président
Rapportrice
Rapportrice
Examinatrice
Co-encadrant de thèse
Co-encadrant de thèse
Co-directeur de thèse
Directeur de thèse

Résumé

L'optimisation des apports azotés représente un enjeu majeur pour réduire les pollutions tout en maintenant un rendement élevé et une qualité satisfaisante de la récolte. Les apports d'azote (N) sont aujourd'hui mal valorisés par les cultures et une meilleure prise en compte de la variabilité spatiale et temporelle des besoins des plantes permettrait d'ajuster ces apports et améliorer leur valorisation. Pour cela, la connaissance du statut azoté du couvert végétal en cours de croissance est primordiale. La présente thèse porte sur le suivi non-destructif de l'indice de nutrition azotée (INN) du blé tendre d'hiver (*Triticum aestivum* L.). Afin de mettre en place la méthode de suivi de l'INN, des essais présentant un gradient de fertilisation ont été étudiés durant trois années. Au cours de cette période, le statut azoté a été évalué au moyen de mesures destructives, par l'utilisation d'un capteur optique foliaire (Dualox, Force A, Orsay), mais aussi au moyen de caméras multispectrales montées sur drone. Les mesures obtenues avec le Dualox ont présenté une corrélation élevée et stable avec l'INN, particulièrement au stade deux nœuds ($r^2 = 0.78$). La première année, des indices de végétation (IV) communément utilisés, calculés à partir de mesures de réflectance dans quatre longueurs d'onde obtenues à l'aide d'une caméra Sequoia (Parrot, Paris, France), ont été évalués. Les corrélations obtenues entre les IV et l'INN étant moyennes et les IV étant peu discriminés entre eux, cela a conduit à l'étude d'une gamme plus large de longueurs d'onde via l'utilisation d'une caméra multispectrale modulable Kernel (Mapir, San Diego, USA) mesurant la réflectance dans 15 longueurs d'onde, de 405 à 940 nm. De nouvelles combinaisons ont ainsi été testées sur la base des formulations de 8 IV. Au total 248 combinaisons ont été évaluées, mettant en évidence l'intérêt des combinaisons associant le vert et le proche infrarouge (NIR) en début d'élongation et les associations du NIR avec la portion orange-début du rouge du spectre en fin d'élongation et au stade gonflement. Quatre modèles de prédiction non paramétriques ont été construits et évalués sur la base des informations collectées. Malgré l'absence d'amélioration des performances par rapport à des combinaisons simples d'IV, ces modèles devraient permettre d'être plus stables grâce à la prise compte d'un nombre plus important de longueurs d'onde que les IV seuls. Le modèle de régression par les moindres carrés partiels (PLS), qui a présenté le plus d'intérêt, a été ensuite combiné avec des mesures prises par proxidétection afin d'améliorer la capacité de prédiction du statut azoté de façon notable. Un modèle combinant mesures prises par proxi- et télédétection a donc été construit et mériterait d'être testé en parcelle agriculteur. Cette étude a été complétée par un suivi des composantes de rendement, mettant en évidence le nombre d'épis par m² comme la composante de rendement la plus influencée par la fertilisation, mais aussi la plus déterminante pour le rendement. Enfin, la dernière partie du travail a porté sur le suivi des performances agronomiques et environnementales de quatre outils d'aide à la décision (OAD) proposés actuellement aux agriculteurs pour piloter la fertilisation. Les OAD, testés de 2017 à 2020 sur une succession culturale orge-blé-colza-blé ont majoritairement conseillé un dépassement de la dose bilan calculée en début de saison. En pratique, dans les conditions des essais, cela ne s'est pas traduit par une amélioration significative des performances à la récolte. En outre, la mauvaise valorisation des apports a conduit à augmenter la teneur en N minéral du sol à la récolte, particulièrement en année sèche, présentant un risque potentiel de lessivage. En perspective à ce travail, une méthode de fertilisation dynamique, basée sur un diagnostic précoce du statut azoté ou de la disponibilité en N minéral, serait pertinente et pourrait être proposée sous forme d'un modèle de suivi de l'INN combinant des mesures prises par proxi- et télédétection.

Mots clés : blé tendre d'hiver, proxidétection, télédétection, fertilisation azotée, indice de nutrition azotée (INN), indice de végétation, efficience de l'utilisation de l'azote

Abstract


Increasing the Nitrogen (N) use efficiency (NUE) to minimize the N pollution while maintaining high crop yield and satisfactory quality at harvest is essential for the development of sustainable agriculture. Better consideration of the spatial and temporal variability of N requirements would allow to adapt N fertilizer rate in space and time to match crops' demand to increase N recovery. Knowledge of the crop's N status during growth should therefore make it possible to improve fertilisation practices. In this context, the main purpose of this thesis project was to make non-destructive monitoring of the winter wheat (*Triticum aestivum* L.) N nutrition index (NNI) during crops' growth. For this purpose, three experimental fields showing various patterns of NNI dynamics were monitored in the North of France. During three years, monitoring was made both on field with destructive measurements and with a leaf-clip sensor (Dualex, Force A, Orsay, France), but also with multispectral cameras embedded on unmanned aerial vehicles (UAV). During the three growing seasons (2019-2021), Dualex leaf-clip presents a stable and relevant application to predict NNI at stage two nodes ($R^2=0.78$). For the first year, commonly used vegetation indices (VI) were calculated from pictures taken by Sequoia camera (Parrot, Paris, France) and evaluated to monitor NNI. The correlation between these VI remains average. According to these results, it was difficult to select a discriminant VI among commonly used VI which confirms the interest in studying new wavelengths to increase VI sensitivity to change in N status. Since 2020, to enhance the investigation of the relationship between VI and NNI, a six-lens multispectral modular camera (Kernel camera, Mapir, San Diego, USA) was used and allow to take picture in 15 wavelengths, from 405nm to 940nm. Measurements taken at 15 wavelengths made it possible to calculate eight VI, with a total of 248 different wavelength combinations. Among these combinations, the combination of green and near-infrared measurements at the beginning of elongation and the associations of the near-infrared with the orange-early red portion of the spectrum at the end of elongation were of interest. Four non-parametric prediction models were then construct and evaluated to consider more explanatory variables than simple VI which combine only few wavelengths' measurements. The partial least squares (PLS) regression model, which was of most interest in this study, was then combined with proximal sensing measurements to significantly improve the ability to predict N status. A prediction model of NNI combining remote and proximal sensing measurements was therefore built and should be tested in a farmer's plot. This study was completed by monitoring yield components, highlighting the number of spikes.m⁻² as the yield component most influenced by fertilisation but also the most determinant for yield. Finally, a second part of this work aims to compare the agronomic and environmental performances of 4 decision support tools (DSTs) used by farmers, with the classical balance sheet method (BSM). This study was made at the crop succession scale (barley-wheat-rapeseed-wheat), from 2017 to 2020. In the context of the trials, the fertilizer N dose advised by DSTs was mostly higher than those calculated with the BSM without any significant increases neither in crop yield nor in grain quality. The excess of fertilizer N was weakly recovered by crop and led to over-fertilization, more pronounced in dry condition. In this context, a dynamic fertilisation method based on a diagnosis of nitrogen status or mineral N availability earlier in the season is relevant and could be based on a NNI monitoring model combining proximal and remote sensing measurements.

Keywords: winter wheat, remote sensing, proximal sensing, Nitrogen Nutrition Index, nitrogen fertilization, vegetation index, nitrogen use efficiency (NUE)

Avant-propos

Cette thèse a été réalisée du 1 février 2019 au 31 janvier 2022, au sein de Junia-ISA, rattachée à l'Unité Mixte de Recherche transfrontalière (UMR-T) INRAE 1158 BioEcoAgro. Cette UMR-T regroupe des chercheurs français et belges travaillant dans le domaine l'ingénierie biologique appliquée à l'agriculture, la biotechnologie, l'agro-alimentaire et l'environnement. Elle est structurée en 3 pôles, regroupant 9 équipes. Ce travail s'inscrit dans le cadre du pôle 1, « Systèmes de culture innovants pour la transition agro-écologique et bioéconomique dans le contexte du changement climatique » et de l'équipe 3, « Conduite, optimisation et conception de systèmes de culture répondant à des objectifs multicritères » (Figure i).

Cette thèse a été menée en lien étroit avec le projet « OAD N » portant sur l'évaluation des performances agroenvironnementales des outils d'aide à la décision en fertilisation azotée, financé par l'Agence de l'Eau Artois Picardie. Ce projet a été conduit de 2017 à 2021, en partenariat avec l'Institut de Genech (lycée agricole) et le Groupe Carré (négoce agricole). Cette thèse a été cofinancée par l'Agence de l'Eau Artois Picardie et JUNIA. Les expérimentations et les analyses effectuées ont été réalisées sur des essais menés par la Chambre d'Agriculture du Nord Pas de Calais.



LES TUTELLES: U. LIEGE-TERRA ● U. LILLE-VIOLETTE ● UPJV-BIOP ● INRAE-AGROIMPACT ●

Figure i : Structuration de l'UMRT 1158 BioEcoAgro (https://www.bioecoagro.eu/umrt-bioecoagro_fre/)

Remerciements

Arrivée au terme de trois années riches et intenses en apprentissages il me revient de remercier les personnes qui ont contribué de près ou de loin à rendre cette expérience aussi enrichissante.

Je ne peux commencer sans adresser mes remerciements à mes encadrants de thèse, Bertrand Vandoorne et Herinaina Andriamandroso. Merci à tous les 2 pour tout ce que vous m'avez apporté au cours de ces 3 ans. Je vous remercie pour votre encadrement, la qualité de vos conseils et des échanges que nous avons eus. Tout cela m'a amenée à me dépasser, à explorer et mobiliser de nouvelles compétences et connaissances, je vous en suis très reconnaissante. Merci également pour l'enthousiasme dont vous avez fait preuve face aux résultats obtenus et qui ont été moteur pour mener ce travail. J'ai beaucoup apprécié travailler à vos côtés !

Mes remerciements vont également à mon directeur de thèse Ali Siah et mon co-directeur de thèse Christophe Waterlot, pour avoir accepté de diriger cette thèse. Merci également pour vos conseils et pour le suivi du bon déroulé de cette thèse.

Je tiens également à remercier les membres de mon comité de pilotage, Joël Léonard, Benjamin Dumont et Benoît Mercatoris pour vos conseils avisés qui m'ont permis de me recentrer sur l'essentiel et de gagner en cohérence.

Je remercie Christelle Gée, Marie-Christine Van Labeke, Stéphanie Delalieux et Benoît Mercatoris d'avoir accepté d'être membres du jury.

Je remercie également JUNIA, établissement ISA, qui m'a accueillie pour la réalisation de cette thèse, ainsi que l'agence de l'eau Artois Picardie qui ont financés ce projet.

Une grande partie de ma thèse s'est appuyée sur des expérimentations. Merci donc aux partenaires du projet OAD N, l'institut de Genech, le groupe Carré et Nord négoce. A l'institut de Genech je remercie chaleureusement Anne Blondeau pour sa disponibilité ainsi que pour son implication et celle de ses étudiants dans le projet. Pour le groupe Carré mes remerciements vont à Philippe Touchais, Alexandre Klein, David Vandenberghe, Fabrice Pattin et Valentine Duneugardin, un grand merci pour votre suivi régulier des essais. Durant ces trois ans j'ai été amenée à suivre des essais de la Chambre d'Agriculture du Nord Pas de Calais, je remercie chaleureusement Christophe Guille pour cette collaboration. Cela a été un plaisir de travailler à nouveau avec toi et nos échanges ont toujours été enrichissants. Merci également à Jérôme Lecuyer pour le suivi technique.

Mes remerciements s'adressent aussi aux stagiaires avec qui j'ai travaillé sur ces projets : Marion, Maxime, Victoria et Manon. Merci pour le travail fourni et pour votre aide précieuse sur le terrain, au labo ou au bureau, je vous en suis très reconnaissante.

Je remercie aussi chaleureusement mes collègues de l'ISA et particulièrement les membres de l'équipe ISAS dont laquelle je fais partie, pour la bonne ambiance générale de l'équipe et échanges enrichissants que nous avons pu avoir. Merci également aux membres de l'équipe PPB avec qui nous partageons les labos, et les pauses café ! J'en profite pour remercier tout particulièrement Sitraka Andrianarisoa qui a été une des premières personnes avec qui j'ai travaillé en arrivant à l'ISA. Je te dois beaucoup en ce qui concerne mes connaissances sur l'azote, les pratiques de terrain et de laboratoire, sois-en remercié ! Merci également pour ta relecture. Merci aussi à tous les collègues qui m'ont donné un coup de main, que ce soit pour m'aider à « éplucher » les épis (au total ce sont 29330 grains qui ont

été comptés grâce à vous) ou pour m'accompagner sur le terrain. Pour la partie labo et terrain, je remercie particulièrement Caroline pour son soutien pratique, Ourida pour s'être occupé avec patience et méticulosité de la préparation de certains échantillons ainsi que Julien pour son aide sur le terrain. Je remercie également ADT drone, et particulièrement Grégory Alvarez qui a conçu le drone et m'a formée avec pédagogie au pilotage de drone. Lors de ma première année de thèse j'ai aussi été amenée à Gembloux, je remercie Sébastien et Alexis pour votre accueil et vos conseils sur la caméra.

J'adresse évidemment mes remerciements aux autres doctorants et ingénieurs d'études de l'étage : Claire, Arthur, Rémi, Justine, Anne-Sophie, Aline, Myriam, Morgane, Renata, Aude, Hélène, Nicolas plus ceux que j'oublie, je m'en excuse. Vous avez contribué à faire de cette thèse une bonne expérience, merci pour tous les bons moments passés avec vous !

Enfin, je remercie également ma famille et mes amis pour leur présence et leurs attentions. Tout particulièrement, je remercie mes parents pour m'avoir toujours encouragée et accompagnée dans mes choix. Enfin, merci Aurélien de m'avoir soutenue et supportée tout au long de cette thèse.

Table des matières

Résumé.....	i
Abstract	ii
Avant-propos.....	iii
Remerciements	iv
Table des matières	vi
Introduction générale.....	1
Etat de l’art.....	3
1. L’azote un élément essentiel au blé et sa répartition dans la plante	4
1.1. Les sources d’azote.....	4
1.2. Le rôle de l’azote pour le blé et ses besoins.....	5
1.3. L’azote dans la plante	7
1.3.1. L’absorption de l’azote et les mécanismes associés	7
1.3.2. L’accumulation de l’azote dans la plante et l’effet de dilution	8
1.3.3. Efficience de l’utilisation de l’N	9
1.4. Notions d’azote critique et d’indice de nutrition azotée (INN).....	10
1.4.1. Définitions	10
1.4.2. Potentiel d’utilisation de l’INN pour améliorer l’efficience des apports.....	11
1.4.3. Limites de l’INN par mesure directe et apport des nouvelles technologies	11
2. Le suivi de l’INN par proxi- et télédétection.....	12
2.1. Les propriétés optiques du couvert en lien avec le statut azoté	12
2.1.1. Les propriétés optiques des feuilles.....	12
2.1.2. Les longueurs d’onde impliquées dans les réactions	12
2.1.3. Estimations à l’échelle du couvert.....	14
2.2. Les indices de végétation	14
2.2.1. Principe et longueurs d’onde utilisées	14
2.2.2. Limites des IV et émergence de nouvelles combinaisons	15
2.2.3. Amélioration des performances des IV	15
2.2.4. Corrélations entre IV calculés à partir d’images drones et paramètres du blé.....	16
2.3. Utilisation de modèles non-paramétriques de prédiction	18

2.3.1.	Limites des modèles paramétriques et principe des modèles non-paramétriques.....	18
2.3.2.	Démarche générale	19
2.3.3.	Indicateur de validation des modèles	20
2.3.4.	Utilisation des modèles non paramétriques sur des données issues de télédétection	20
2.4.	Mesures par proxidtection	22
2.5.	Mesures par télédétection	25
2.5.1.	Vecteurs.....	25
2.5.2.	Caméras.....	26
2.5.3.	Traitement des images prises par un drone.....	27
3.	Enjeux de la gestion de l'azote	29
3.1.	La fertilisation azotée minérale et les enjeux associés	29
3.2.	Pilotage actuel de la fertilisation.....	30
3.2.1.	La méthode du bilan.....	30
3.2.2.	Ajustement de la dose bilan en cours de campagne (date, dose, spatialisation)	32
	Problématique, objectifs et démarche de thèse	35
	Résultats.....	39
	Chapitre I	40
	Abstract.....	42
	Introduction	42
	Materials and methods.....	43
	Results and discussion	46
	Conclusions.....	49
	Chapitre II	52
	Abstract	54
1.	Introduction.....	55
1.1.	Monitoring N-status by remote sensing.....	55
1.1.1.	Leaf optical properties and their relationship with physical and biological characteristics.....	55
1.1.2.	Indirect estimation of nitrogen nutrition index (NNI).....	55
1.1.3.	Improving N-status prediction using models	56
2.	Materials and Methods	57

2.1.	Experimental sites and fertilization rates.....	57
2.2.	Crop analysis and ground level measurements	59
2.3.	UAV image acquisition and processing	59
2.4.	Data analysis.....	60
2.4.1.	NNI determination by different algorithms: model training and cross-validation	60
2.4.2.	Model validation and testing on an independent dataset.....	62
3.	Results	63
3.1.	NNI dynamics in 2020 and 2021.....	63
3.2.	Correlation analysis between individual wavelength combinations and NNI.....	63
3.2.1.	Combination selection according to RMSE per VI.....	63
3.2.2.	Combination selection according to RMSE regardless of the VI formulation	64
3.3.	Validation of different NNI prediction models.....	65
3.3.1.	Cross-validation	65
3.3.2.	Models validation.....	67
3.4.	Models testing.....	68
3.4.1.	Testing 2020 models on the 2021 dataset	68
3.4.2.	Testing 2021 models on the 2020 dataset	68
4.	Discussion.....	71
4.1.	Monitoring NNI with UAV-based VI: wavelengths and VI of interest	71
4.1.1.	Wavelength selection.....	71
4.1.2.	Difficulty in extracting an effective VI in a wide range of situations.....	72
4.2.	Evaluation of different NNI prediction models	73
4.2.1.	Relevant application of Ridge, PLS and PCR models on the training and validation dataset	73
4.2.2.	Testing models: interest of PLS and PCR models	74
4.2.3.	Parameters influencing the predictive quality of the models.....	74
5.	Conclusion	75
	References.....	77
Chapitre III		81
	Abstract :	84
1.	Introduction.....	85
2.	Materials et methods	87
2.1.	Experimental sites and fertilisation rates.....	87
2.2.	Crop analysis and ground level measurements	89
2.3.	Proximal sensing measurements.....	89

2.4.	Remote sensing measurements	89
2.5.	Data analysis.....	90
2.5.1.	Proximal sensing.....	90
2.5.2.	Remote sensing	92
3.	Results	92
3.1.	Correlation between NNI and NBI.....	92
3.2.	VIs and wavelengths evaluation.....	93
3.3.	NNI estimation by parametric and non-parametric modelling algorithms.....	94
3.3.1.	Models training	94
3.3.2.	Models cross-validation and validation.....	94
3.3.3.	Models testing.....	95
4.	Discussion	96
4.1.	Predicting NNI by proximal sensing.....	96
4.2.	Operational non-parametric model to predict NNI	97
4.3.	Improving NNI prediction accuracy by combining proximal and remote sensing	98
5.	Conclusion:	99
	References:.....	101
Chapitre IV		106
	Abstract	108
1.	Introduction.....	109
2.	Materials and methods	112
2.1.	Experimental sites and fertilization rates.....	112
2.2.	Climate data	115
2.3.	Crop analysis and ground level measurements	116
2.3.1.	Apparent Nitrogen Recovery (ANR) and Nitrogen Nutrition Index (NNI)	116
2.3.2.	Yield components.....	116
2.4.	Data analysis.....	117
2.4.1.	Study of the effect of fertilization	117
2.4.2.	Relationships between yield components	117
3.	Results	118
3.1.	Results at harvest	118
3.2.	Study of the relationships between yield components and harvest results.....	121
3.2.1.	2020: Savy.....	121
3.2.2.	2021: Frevillers	121
3.3.	Effect of fertilization on yield components	122

3.3.1.	Effect of fertilization strategies	122
3.3.2.	Effect of the fertilization N accumulation per application stage	123
3.4.	NNI dynamics in 2020 and 2021.....	124
3.5.	ANR evolution according to fertilization strategies	126
3.5.1.	2020: Savy.....	126
3.5.2.	2021: Frévilleurs	126
4.	Discussion	127
4.1.	Results at harvest	127
4.2.	Yield components	128
4.2.1.	Plant.m ⁻² and grains.spike ⁻¹ : different relations for the 2 years.....	128
4.2.2.	Spikes.m ⁻² and TGW: general trend for the 2 years.....	128
4.3.	Effect of fertilization on spikes.m ⁻²	129
4.4.	NNI and fertilization strategies.....	129
4.5.	Apparent N recovery (ANR).....	130
5.	Conclusion	131
	References:.....	132
 Chapitre V.....		136
	Abstract:.....	138
1.	Introduction.....	139
2.	Materials and Methods	140
2.1.	Study sites.....	140
2.2.	Field measurements.....	144
2.2.1.	Agronomic parameters.....	145
2.2.2.	Environmental parameters.....	146
2.2.3.	Statistical analysis.....	147
3.	Results	147
3.1.	Overall synthesis of N fertilization, crop yield and grain quality.....	147
3.2.	Agronomic performances of DSTs.....	148
3.2.1.	Performances over the crop succession.....	148
3.2.2.	Diagnoses of fertilizer N strategies advised by DSTs at crop year level	149
3.2.3.	Diagnosis of crop response to N fertilizer	149
3.3.	Environmental performances of DSTs.....	152
3.3.1.	Evolution of soil mineral nitrogen (SMN) content in balance sheet method (BSM) treatment	152
3.3.2.	Evolution of SMN for DSTs treatments	154

3.3.3.	Apparent N recovery for wheat in 2018 and 2020.....	155
3.3.4.	Diagnostic of wheat over-fertilization.....	157
4.	Discussion	158
5.	Conclusion	161
	References:.....	163
	 Discussion générale et perspectives	 166
1.	La télédétection permet-elle de mesurer efficacement l'INN ?.....	167
1.1.	Exploration de nouvelles gammes de longueurs d'onde	169
1.2.	Etude de modèles de régression non-paramétriques.....	171
2.	Malgré les limites de la télédétection, peut-on évaluer efficacement le statut azoté du blé de façon non destructive ?.....	175
2.1.	Exploration du potentiel d'une approche combinée utilisant la proxo- et télédétection dans le but d'obtenir un modèle de prédiction de l'INN opérationnel	175
2.2.	Perspectives d'application à court terme.....	178
3.	Quel compromis avoir entre les méthodes de pilotage actuelles et les perspectives offertes par la combinaison des mesures prises par proxo- et télédétection pour suivre le statut azoté ?	180
3.1.	Constats sur les performances des OAD	180
3.2.	Perspectives ouvertes par le pilotage dynamique	180
	 Conclusion	 185
	 Références bibliographiques	 188
	 Annexes	 199

Liste des abréviations

%N : *N concentration*/teneur en azote dans les parties aériennes de la plante
%Nc : *critical N concentration*/teneur en azote critique
ΔN : *excess of soil mineral nitrogen content observed at harvest*/ excès d'azote minéral du sol observé à la récolte (kg N.ha⁻¹)
ACP : Analyse en composante principale
AIC : *Akaike's Information Criterion*
ANN : *Artificial neural networks*/ Réseau de neurones artificiel
ANOVA : *Analysis of variance*/Analyse de la variance
ANR : *Apparent Nitrogen Recovery*/Coefficient apparent d'utilisation de l'azote
ARVI : *Atmospherically Resistant Vegetation Index*
ASD : *Analytical Spectral Devices*
BSM : *Balance sheet method*/méthode du bilan
Comifer : Comité Français d'Etude et de Développement de la Fertilisation Raisonnée
DBM : *Dynamic Balance method*/méthode du bilan dynamique
DM : *Dry biomass*/biomasse sèche
DST : *Decision Support Tool*/outil d'aide à la décision (OAD)
ELC : *Empirical light correction*
FAO : *Food and Agriculture Organisation*
GARI : *Green Atmospherically Resistant Vegetation Index*
GgN.an⁻¹ : Gigagramme d'azote par an
GNDVI : *Green Normalized Difference Vegetation Index*
GNSS : *Global Navigation Satellite System*
GOSAVI : *Green Optimized Soil Adjusted Vegetation Index*
GREN : Groupes Régionaux d'Expertise Nitrates
GRVI : *Green Ratio Vegetation Index*
GS : *Growing stage*/Stade de croissance
H₂ : dihydrogène
Ha : hectares
HVB : *Hue, Saturation, Brightness*/ teinte, saturation et luminosité
ILSC : *Light intensity sensor correction*
IMU : *Inertial Measurement Unit*
INN : indice de nutrition azotée
IV : Indice de Végétation
kg N.ha⁻¹ : kg d'azote par hectare
kg N.q⁻¹ : kg d'azote par quintal produit
LAI : *Leaf Area Index*/indice de surface foliaire
MCARI : *Modified Chlorophyll Absorption Ratio*
Mha : millions d'hectare
MSAVI : *Modified Soil Vegetation Adjusted Index*
MT : millions de tonnes
MTVI : *Modified Triangular Vegetation Index*
N : *Nitrogen*/azote
N₂ : azote atmosphérique (diatomique)/diazote gazeux
N₂O : protoxyde d'azote
NBI : *Nitrogen Balance Index*

N_c : N critique
NDRE : *Normalized Difference Red Edge*
NDVI : *Normalized Difference Vegetation Index*
NH₃ : ammoniac
NH₄⁺ : ammonium
NIR : *Near InfraRed*/proche infrarouge
NNI : *Nitrogen Nutrition Index*/Indice de nutrition azotée
NO₃⁻ : nitrate
NO_x : oxyde d'azote
NUE : *Nitrogen Use Efficiency*/Efficience de l'utilisation de l'azote mineral
NUPE : *N uptake efficiency*/Efficience d'absorbtion de l'azote
NUtE : *N utilization efficiency*/ Efficience d'utilisation de l'azote
OAD : Outil d'Aide à la Décision
OF : *Over Fertilization*/sur-fertilisation (Beaudoin et al., 2005)
OSAVI : *Optimized Soil Adjusted Vegetation Index*
PCA : *Principal Component Analysis*
PCR : *Principal Component Regression*/ Régression en composantes principales
PLS : *Partial Least Squares Regression*/ Régression des moindres carrés partiels
PRESS : *Predicted RResidual Sum of Squares*/Somme des carrés de l'erreur résiduelle prédite
PS : *Proximal Sensing*/proxidétection
PSO-SVR : *Particle Swarm Optimization-based Support Vector Regression model*
R² : coefficient de détermination
RDVI : *Reformed Difference Vegetation Index*
REIP-LI : *Red Edge Inflection Point:Linear Interpolation Method*
RF : *Random Forest*/Forêt aléatoire
RGB : *Red Green Blue*/Rouge Vert Bleu
RMSE : *Root mean square error*/Erreur quadratique moyenne
RS-S : *Remote Sensing-satellite*/télédétection par satellite
RS-U : *Remote Sensing-UAV*/télédétection par drone
SAVI : *Soil Adjusted Vegetaiton Index*
SMN content: *Soil Mineral N content*/contenu en azote mineral du sol
SR : *Simple Ratio*
SVM : *Support vector machines*
SVR : *Support Vector Regression model*
SWIR : *Short Wave Infra Red*/infrarouge à ondes courtes
TCARI : *Transformed Chlorophyll Absorption in Reflectance Index*
TDVI : *Transformed Difference Vegetation Index*
TGW : *Thousand Grain Weight*/poid de mille grains (PMG)
UAV : *Unmanned Aerial Vehicle*/Drone
UV : Ultraviolet
VI : *Vegetation Indice*/Indice de végétation
VIS : visible
wl : wavelength/longueur d'onde

Introduction générale

Le blé (*Triticum aestivum* L.) est la céréale la plus cultivée au monde. En 2019, 215 Mha sont consacrés à cette culture contre 197 Mha pour le maïs et 162 Mha pour le riz. La production mondiale de blé atteint 765 MT en 2019. L'Asie est le premier continent producteur (44% de la production mondiale), suivi par l'Europe (35%) et l'Amérique (15%) (FAO, 2021). En Europe, la France est le premier pays producteur et exportateur de blé (FranceAgriMer, 2020). La production française de blé représente plus d'un quart de la production de l'Union Européenne et un tiers des exportations, ce qui souligne l'importance de cette culture au niveau national (Charmet et al., 2017). Le blé est la source de 20% des calories et des protéines dans l'alimentation humaine (Foulkes et al., 2011). A l'échelle mondiale, le blé est largement exporté, 180 MT exportées en 2019, soit 23.5% de la production globale (FAO, 2021). En effet, la demande en blé se mondialise tandis que sa production reste localisée (Abis, 2015).

Dans le contexte actuel de croissance démographique et d'accélération de la demande (de 300 à 700 MT entre 1970 et 2010), l'augmentation du rendement est une nécessité afin d'assurer la sécurité alimentaire (Foulkes et al., 2011 ; Abis, 2015). Toutefois, dans une démarche de durabilité, cette augmentation devra se faire tout en limitant l'impact sur l'environnement et en gérant durablement les ressources, notamment en eau et en azote (N) (Pellerin et al., 2014). Pour répondre à ce double défi, des améliorations génétiques sont réalisées, pour obtenir des variétés productives et économes en intrants (Gastal et al., 2015). Selon la FAO (2021), l'Europe de l'Ouest est très compétitive du point de vue de la sélection variétale. En France, le rendement potentiel des variétés croît en moyenne de 1.1% par an (1950 à 2008, Brisson et al., 2010 in Fischer, 2014). Cependant, en pratique, cela nécessite également de raisonner et d'adapter les pratiques agricoles. Ainsi, concernant la fertilisation, l'amélioration de l'efficacité des apports est primordiale (Foulkes et al., 2011 ; Gastal et al., 2015 ; Späti et al., 2021).

La gestion des éléments minéraux est en effet essentielle pour répondre aux problématiques de production et de durabilité. Le recours à la fertilisation a notamment permis une augmentation notable de la production. Selon Pellerin et al. (2014), la production alimentaire mondiale a été multipliée par 2.5 entre 1961 et 2006. Cela s'est accompagnée d'une multiplication par 8 de la quantité d'engrais minéraux azotés apportés pour la même période. Or, il est avéré que les fertilisants minéraux sont également des polluants potentiels de l'environnement (Pellerin et al., 2014). Le travail de Leip et al. (2011) sur la modélisation des flux d'N à l'échelle européenne met en évidence un surplus d'N dans les sols agricoles de 12530 GgN.an⁻¹ pour l'année 2002. Ce surplus d'N est à l'origine de problèmes environnementaux et principalement à la suite de son lessivage hors des horizons racinaires (estimé à 45% du surplus) (Leip et al., 2011). La pollution azotée serait d'ailleurs la troisième menace majeure pour la planète après la perte de biodiversité et le changement climatique (Giles, 2005).

Améliorer l'efficacité de la valorisation des apports de fertilisants minéraux azotés par les cultures, en synchronisant les dates et doses d'apport à la variabilité spatiale et temporelle des besoins en N du couvert, représente donc un enjeu de taille pour réduire les pollutions tout en maintenant un rendement élevé et une qualité satisfaisante à la récolte. Pour cela, une meilleure considération des besoins en N de la culture en cours de croissance permettrait d'ajuster ces apports et ainsi d'améliorer leur valorisation. Pour parvenir à cela, la connaissance du statut azoté du couvert végétal en cours de croissance est primordiale. Dans ce contexte, les estimations indirectes du statut azoté par proxi- ou télédétection sont intéressantes (Lemaire, 2019), permettant des mesures rapides, non destructives et répétables en cours de croissance (Chen, 2015). Ainsi, le travail réalisé durant cette thèse porte sur

le suivi et l'évaluation non-destructive de l'indice de nutrition azotée (INN) du blé tendre en cours de campagne dans le but d'intégrer par la suite ces connaissances dans une démarche de pilotage dynamique de la fertilisation azotée et améliorer de la sorte la valorisation des apports par la culture en apportant la juste dose en fonction des besoins mesurés. Le présent manuscrit débutera par un état de l'art permettant de définir le contexte dans lequel ce travail a été réalisé. Par la suite, les principaux résultats seront détaillés sous forme de 5 articles scientifiques. Enfin, une discussion générale clôturera ce manuscrit par une synthèse des résultats obtenus et une présentation des perspectives ouvertes par ce travail.

Etat de l'art

1. L'azote un élément essentiel au blé et sa répartition dans la plante

L'azote (N) est parmi les éléments les plus abondants sur Terre. Cependant, il reste un facteur limitant pour la croissance de la plupart des plantes et son absorption est déterminante pour le rendement et la qualité à la récolte (Hawkesford et al., 2012 ; Gastal et al., 2015, Bao et al., 2013). En effet, avec le carbone, l'hydrogène, l'oxygène et le soufre, l'N fait partie des constituants majeurs de la matière organique. Ces éléments interviennent dans la constitution des acides aminés, des protéines et des enzymes. L'N représente 1 à 5% de la matière sèche d'une plante (Hawkesford et al., 2012).

1.1. Les sources d'azote

L'N est présent dans la nature sous deux états, (i) l'N diatomique (N_2) qui constitue environ 80% de l'atmosphère et (ii) l'N réactif sous forme minérale ou organique (Cellier, 2019). Hormis pour les plantes capables de fixer l'N atmosphérique (N_2) par symbiose, la source majeure d'N pouvant être absorbé par les racines des plantes se trouve sous forme de nitrate (NO_3^-) et d'ammonium (NH_4^+) qui correspondent à la fraction d'N sous forme minérale (Hawkesford et al., 2012).

Dans une parcelle agricole, le stock d'N minéral est alimenté par différents flux, parmi lesquels se trouvent : les dépôts atmosphériques, les apports de fertilisants azotés minéraux ainsi que l'N minéral issu des processus biologiques de transformation de l'N organique (matière organique des sols, fumier, lisier, digestats, etc.) (Figure 1). En effet, la plupart de l'N du sol est présent sous forme de molécules organiques complexes, qui sont converties (i) en ammonium par minéralisation par les micro-organismes du sol et (ii) en nitrate par un processus de nitrification de l'ammonium (Miller et Cramer, 2004). A cette étape, des pertes sous forme de protoxyde d'N peuvent survenir (N_2O).




Figure 1 : Cycle de l'azote dans les agroécosystèmes (Unifa, 2019)

Le nitrate et l'ammonium sont donc naturellement présents dans la solution de sol, le nitrate a une concentration de 1-5mM et l'ammonium en plus faible quantité a une concentration de 20-200µM (Owen and Jones, 2001 in Miller et Cramer, 2004). La majorité des plantes cultivées assimilent préférentiellement le nitrate à l'ammonium. En effet, ce premier est plus soluble dans l'eau donc plus mobile et rapidement assimilé contrairement à l'ammonium, chargé positivement, qui se fixe sur les minéraux du sol et ce dernier est par conséquent moins mobile (Morot-Gaudry, 1997).

Les réactions sont influencées par les caractéristiques du sol (pH, conditions d'aérobic/d'anaérobic, déficit/excès en eau, température) (Miller et Cramer, 2004). Ainsi, dans certaines conditions, des processus de pertes d'N peuvent survenir. Les processus impliqués sont la lixiviation, la dénitrification et la volatilisation. Ces pertes peuvent également être dues à des apports excessifs de fertilisants azotés (Cellier, 2019). La lixiviation correspond à l'entraînement du nitrate hors du profil racinaire par les eaux de drainage. Quant à la volatilisation, il s'agit du processus de transformation de l'ammonium en ammoniac (NH₃), dégagé dans l'atmosphère. Cette réaction peut être importante en condition de sols secs et à pH élevé (Unifa, 2019). Enfin, la dénitrification a lieu en condition d'anaérobic et consiste à la transformation du nitrate en diazote gazeux (N₂) et en moindre mesure en protoxyde d'N (N₂O) et oxydes d'N (NO_x) libérés dans l'atmosphère.

1.2. Le rôle de l'azote pour le blé et ses besoins

La production de blé est contrainte par l'atteinte d'un rendement objectif et une qualité à la récolte qui est déterminante pour sa commercialisation (Brown et al., 2005). La teneur en protéines du grain est un critère de qualité parmi les plus utilisés et cela quel que soit le débouché de la récolte (alimentation humaine, animale, pays de destination, etc.). Le seuil minimal est de 10.5% et le seuil idéal de 11.5% (Charmet et al., 2017). Parvenir à ces objectifs va dépendre, d'une part, du potentiel permis par le contexte pédoclimatique mais également de la couverture des besoins en N de la culture (Comifer, 2013). Les besoins totaux du blé varient entre 2.8 kg d'N par quintal de grain produit (kg N.q⁻¹) et 3.5 kg N.q⁻¹ pour des blés améliorants à haute teneur en protéines (Charmet et al., 2017). La quantité d'N absorbée est proportionnelle à la biomasse totale du blé dans des conditions non limitantes (Lemaire et Gastal, 1997).

Les besoins en N du blé vont dépendre des stades de croissance et peuvent être décomposés en trois phases. Le blé débute son développement par une étape durant laquelle les besoins sont faibles, cela se traduit par une faible accumulation de l'N dans la plante. Cette première phase a lieu de l'émergence au tallage. Les besoins du blé vont devenir plus importants dès l'élongation et ce, jusqu'à l'épiaison. Cette période est consacrée au développement de la partie végétative de la plante. Enfin, une troisième phase est caractérisée par un ralentissement de l'absorption qui correspond à une réallocation de l'N des feuilles et tiges vers le grain (Brown et al., 2005 ; Orloff et al., 2012 ; Gastal et al., 2015). Ainsi, après la floraison les feuilles entrent en sénescence et sont source de carbohydrates et d'N réduits pour le développement des organes de stockage (graines, fruits, racines, etc.) (Gastal et al., 2015). En moyenne 75% de l'N des grains à maturité proviennent de la remobilisation (Simpson et al., 1983 in Charmet et al., 2017). Cependant la plante ne perd pas sa capacité d'absorption après la floraison. Si les conditions sont favorables, l'N absorbé sera directement valorisé dans les grains (Charmet et al., 2017).




Figure 2 : Schéma de mise en place des composantes de rendement en fonction des stades phénologiques du blé (Arvalis, 2018)

Les besoins en N en début de saison, avant la floraison, sont essentiellement liés à la mise en place des composantes de rendement (Figure 2), à savoir (i) le nombre de talles fertiles par unité de surface qui donnera le nombre d'épis par unité de surface, (ii) le nombre de grains par épis et donc (iii) le nombre de grains par unité de surface (Orloff et al., 2012). Ainsi, selon Orloff et al. (2012) une carence en début de cycle aura un impact sur les composantes de rendement et sera préjudiciable pour la récolte. Cette observation n'est cependant pas partagée par tous. Des études ont mis en évidence que des carences en N temporaires, durant la phase végétative, ne sont pas nuisibles pour le rendement s'il n'y a pas de carences à floraison (Jeuffroy et Bouchard, 1999). Selon Gastal et al. (2015), la période critique se situerait aux alentours de la floraison. Cette période correspond au pic d'absorption par la plante et un déficit en N à ce stade aurait un impact négatif sur le nombre de grains et donc sur le rendement (Gastal et al., 2015).

Au contraire, à partir de la floraison, le remplissage du grain débute, cela impactera le poids du grain et l'N valorisé exercera une influence significative sur la teneur en protéine des grains (Slafer et al., 2014). Dans une moindre mesure, l'N en fin de cycle peut augmenter la taille du grain mais ce n'est pas le facteur principal qui définit le rendement (Orloff et al., 2012 ; Calderini et al., 2021). En effet, selon Slafer et al. (2014) le nombre de grains par unité de surface est le premier déterminant du rendement. Enfin, le nombre de grains et le poids du grain sont négativement corrélés entre eux. Ainsi, si une carence réduit le nombre de grains, le remplissage peut permettre de compenser cette réduction en augmentant le poids du grain (Gastal et al., 2015).

Toutefois, malgré la présence naturelle d'N minéral dans le sol, l'N reste un facteur limitant principal de la productivité (Gastal et al., 2015). Pour éviter toute carence en N du blé, les agriculteurs ont massivement recours à la fertilisation azotée. Dans la pratique, cela se traduit par une augmentation de la consommation annuelle d'N à des fins agricoles de 107 MT en 2019, contre 11 MT en 1961 (FAO, 2021). A l'échelle de la France, cette consommation atteint 2MT en 2019 et se traduit par des apports moyens de 112 kg N.ha⁻¹. Cette quantité était de 29 kg N.ha⁻¹ en 1961 et elle a atteint son maximum de 141 kg N.ha⁻¹ en 1989 (FAO, 2019). Les apports en fertilisants minéraux sont principalement réalisés lors de l'élongation, les besoins de la plante pour sa croissance augmentent tandis que les sols, encore froids en sortie d'hiver, ne minéralisent pas encore suffisamment (Charmet et al., 2017). Le raisonnement de la fertilisation et les enjeux associés seront détaillés par la suite.

1.3. L'azote dans la plante

L'accumulation d'N dans la plante dépend d'une part des fournitures et de la disponibilité des éléments minéraux du sol, et d'autre part du potentiel de croissance de la culture qui va réguler l'absorption de l'N (Justes et al., 1994 ; Gastal et Lemaire, 2002 ; Gastal et al., 2015 ; Masclaux-Daubresse et al., 2010 ; Briat et al., 2020). Il s'agit donc d'une co-régulation. En effet, la croissance des plantes, notamment la production de biomasse et la surface des feuilles, vont déterminer leur demande en éléments minéraux et contrôler en retour leur absorption (Briat et Lemaire, 2021). L'assimilation de l'N dans la plante nécessite différentes étapes : l'absorption, l'assimilation, la translocation, le recyclage et la remobilisation de l'N (Masclaux-Daubresse et al., 2010).

1.3.1. L'absorption de l'azote et les mécanismes associés

L'absorption de l'N a lieu au niveau des racines, préférentiellement sous forme de nitrate et d'ammonium grâce à l'action de protéines de transport spécialisées situées dans la membrane plasmique des cellules racinaires. Deux systèmes de transport du nitrate dans la plante agissent de manière coordonnée en fonction de la concentration en éléments minéraux du sol (Briat et al., 2020). Lemaire et Ciampitti (2020) et Gastal et al. (2015) identifient dans la littérature 3 types de régulation de l'absorption d'N : (i) une simulation rapide dépendante de la quantité d'N du sol, (ii) un rétrocontrôle négatif à plus long terme correspondant au signal envoyé par la plante, lié au stockage d'N dans les nouveaux organes et à la couverture de ses besoins afin de moduler l'absorption et (iii) un rétrocontrôle positif lié à l'augmentation de la surface foliaire et à la photosynthèse (Gastal et al., 2015). (Figure 3). L'intensité des rétrocontrôles va dépendre de la croissance de la culture afin de moduler l'absorption d'N. En phase de croissance, la surface des feuilles augmente et accroît le rétrocontrôle positif tandis que la séquestration d'N dans les parties aériennes va inhiber le rétrocontrôle négatif vers les racines. Au contraire, lorsque la croissance est ralentie, le rétrocontrôle positif diminue et le rétrocontrôle négatif s'intensifie (Gastal et al., 2015).




Figure 3 : Schéma des mécanismes de régulation de l'absorption d'azote par la plante en cours de croissance. Trois types de régulations de l'absorption coexistent : une régulation en fonction de la quantité d'azote du sol, un rétrocontrôle négatif lié au stockage d'azote dans les nouveaux organes et un rétrocontrôle positif lié à l'augmentation de la surface foliaire et à la photosynthèse (d'après Lemaire et Ciampitti, 2020)

1.3.2. L'accumulation de l'azote dans la plante et l'effet de dilution

L'accumulation d'N dans la plante en fonction de l'augmentation de la biomasse n'est pas linéaire. L'absorption d'N par unité de biomasse additionnelle va diminuer lorsque la plante croît. Ainsi, la relation entre la concentration en N et la biomasse est formulée de la façon suivante par Justes et al. (1994) :

$$\text{Concentration N (\%N)} = aDM^b \quad (\text{Eq. 1})$$

Avec DM la biomasse sèche ($T \cdot ha^{-1}$) et le contenu en N exprimé en pourcentage de la biomasse sèche.

Cette équation considère la distribution de l'N dans la plante comme étant uniforme, mais en réalité cela varie en fonction de l'environnement lumineux (position de la feuille, ombrage, densité du couvert), de l'âge de la feuille et de la fluctuation des ressources du sol (Gastal et al., 2015). En effet, la répartition de la plante va en grande partie être dépendante de la compétition pour la lumière, l'N va préférentiellement être alloué aux feuilles bien éclairées afin de maximiser l'efficacité de l'utilisation du rayonnement (Hirose et al., 1987 in Lemaire et Ciampitti, 2020). L'N va être alloué de façon préférentielle aux feuilles les plus éclairées tandis que l'N des feuilles les plus ombragées va être recyclé pour permettre le développement de nouvelles feuilles à la surface du couvert ce qui explique le processus de dilution (Lemaire et Ciampitti, 2020). La biomasse peut être divisée en 2 compartiments : (i) les tissus métaboliques impliqués dans les processus de croissance ont une teneur en N élevée (4-5%), tandis que (ii) les tissus structuraux ont une faible concentration en N (0.5-0.7%) (Gastal et al., 2015 ; Briat et Lemaire, 2021). Enfin, la concentration en N de la dernière feuille est la plus stable (Gastal et al., 2015).

1.3.3. Efficience de l'utilisation de l'N

Améliorer la valorisation de l'N est crucial pour optimiser la production et adopter une gestion plus durable des ressources (Foulkes et al., 2011 ; Masclaux-Daubresse et al., 2010 ; Sharma et Bali, 2017). L'efficience de l'utilisation de l'N est traduite par le calcul du NUE (*Nitrogen Use Efficiency* ou Efficience de l'utilisation de l'N) qui correspond au ratio entre les sorties d'N (N total dans la plante, contenu en N des grains, rendement, etc.) et les entrées d'N (N du sol, N apporté par fertilisation, N total) (Masclaux-Daubresse et al., 2010 ; Sharma et Bali, 2017). En pratique, il équivaut souvent à l'augmentation du rendement par unité d'N supplémentaire apportés, ce qui fournit une information sur la valorisation des pratiques de fertilisation par la culture (Gastal et al., 2015 ; Sharma et Bali, 2017 ; Dobermann et Cassman, 2005). Celui-ci peut être divisé en 2 composantes : l'efficacité d'absorption (*N-uptake efficiency*) et l'efficacité d'utilisation de l'N (*N-utilization efficiency*) (Moll et al., 1982 in Gastal et al., 2015). Le NUE va donc être dépendant : (i) du potentiel de la plante, en lien avec sa génétique (ex : densification du système racinaire, efficience du transport de l'N, etc.), (ii) des conditions extérieures et de la disponibilité en N (contexte pédo-climatique), (iii) des pratiques culturales, (iv) de l'interaction entre les 3 premières conditions (Gastal et al., 2015).

Actuellement, à l'échelle mondiale, le NUE en céréales est en moyenne de 35%, une valeur relativement faible qui n'a pas augmenté ces dernières années (Omara et al., 2019) (Figure 4). Cela signifie qu'un tiers seulement des apports sont valorisés par la plante (Sharma et Bali, 2017). Barraclough et al. (2010 in Charmet et al., 2017) expliquent cela par une multiplication des quantités d'N apportées au niveau mondial par 7.4 entre 1970 et 2010, tandis que les rendements n'ont été multipliés que par 2.4 sur cette période. Raun et al., 1999, Cassman et al., 2002 et Abebe et al., 2017 (in Sharma et Bali, 2017), identifient les pratiques suivantes à l'origine de ce faible NUE : (i) le manque de synchronisation entre les apports et les besoins, (ii) les apports uniformes dans le temps et l'espace. Ainsi, la connaissance du statut azoté de la culture en cours de croissance devrait permettre d'améliorer les pratiques de fertilisation et augmenter le NUE.




Figure 4 : Evolution de la tendance entre le NUE estimé pour les céréales (blé, maïs, riz, orge, sorgho, millet, avoine, seigne) en fonction des années pour les Etats-Unis, la Chine et le monde entre 2002 et 2015. NUE estimé = (azote minéral issu de la fertilisation – azote minéral du sol)/consommation d'azote total. (Omara et al., 2019)

1.4. Notions d'azote critique et d'indice de nutrition azotée (INN)

1.4.1. Définitions

Le lien entre biomasse et contenu en N a amené Justes et al. (1994) à travailler sur la notion d'N critique (N_c), définie comme la concentration en N minimale à une biomasse donnée qui permet de maximiser la biomasse. Pour la culture de blé tendre d'hiver, N_c est calculé d'après l'équation suivante en fonction de la biomasse sèche (DM en $T \cdot ha^{-1}$) (Justes et al., 1994) :

$$\text{Si } DM < 1.55 \text{ T} \cdot \text{ha}^{-1} \text{ alors } \%N_c = 4.4, \text{ si } DM > 1.55 \text{ T} \cdot \text{ha}^{-1} \text{ alors } \%N_c = 5.35 \cdot DM^{-0.442} \quad (\text{Eq. 2})$$

Ainsi, pour une biomasse donnée, la comparaison entre le contenu en N mesuré ($\%N_{obs}$) et le N_c ($\%N_c$) va permettre d'estimer un déficit ou un excès d'N (Justes et al., 1994). En dessous de la courbe d' N_c , la culture est déficitaire en N tandis qu'une teneur en N supérieure au N_c correspond à un excès azoté qui ne sera pas valorisé sous forme de biomasse (Figure 5). Cette notion peut se traduire par le calcul de l'INN (indice de nutrition azotée) correspondant au ratio $\%N_{obs}/\%N_c$ (Gastal et Lemaire, 2002). Initialement, l'INN de référence était donc de 1. Une valeur en dessous de 1 indique une déficience en N et un excès lorsque l'INN excède 1 (Gastal et Lemaire, 2002). Par la suite, des travaux ont mis en évidence que ce seuil pouvait être revu à la baisse, notamment en début de cycle, afin de prendre en compte la notion de carence en N non préjudiciable pour la culture aux premiers stades (Jeuffroy et Bouchard, 1999).




Figure 5 : Teneur en azote des parties aériennes en fonction de la biomasse, en trait plein la courbe d'azote critique pour la culture de blé tendre d'hiver, $\%N_c$ la teneur en N critique et $\%N_{obs}$ la teneur en N mesurée pour la biomasse considérée (Justes et al., 1997)

1.4.2. Potentiel d'utilisation de l'INN pour améliorer l'efficacité des apports

Plusieurs études mettent en évidence l'importance de déterminer le statut azoté pour ajuster la dose d'apport et évaluer la croissance de la culture (Aranguren et al., 2020). Le suivi de l'INN va permettre d'évaluer en cours de croissance si la concentration en N dans la plante va permettre d'atteindre la biomasse optimale par comparaison avec un INN de référence (Aranguren et al., 2020). Le suivi de l'INN est d'autant plus intéressant qu'il est un indicateur à la fois spécifique (varie uniquement avec la nutrition azotée) et sensible (réactif aux changements de nutrition) (Lemaire et Meynard, 1997).

L'absorption d'N étant coréglée par le potentiel de croissance et la disponibilité en N du sol, l'INN renseigne également sur la disponibilité en N et la capacité de l'N à circuler dans le système sol-plante-microorganismes qui ont permis à la culture d'atteindre un certain niveau de nutrition (Lemaire, 2019). L'INN serait donc un double indicateur, à la fois de production et du risque environnemental lié à l'N et permettrait par niveau de biomasse de trouver un optimum entre production et prise en compte de l'environnement (Lemaire, 2019). Ainsi, par le biais de l'INN, la plante elle-même est un indicateur de son statut azoté mais également de son milieu. L'utilisation de l'INN permettrait ainsi de se passer de pronostic et d'avoir une approche par diagnostic plus adaptée au contexte et à la culture (Lemaire, 2019).

Dans une stratégie d'amélioration du NUE, la connaissance du statut azoté via l'INN présente une perspective intéressante. Sachant que la demande en N et son absorption sont largement déterminés par la croissance de la culture, l'INN permet d'estimer le statut azoté de la culture en cours de croissance afin de synchroniser les périodes propices à la valorisation des apports et les dates/doses d'apports (Lemaire et Ciampitti, 2020 ; Sharma et Bali, 2017 ; Gastal et al., 2015).

1.4.3. Limites de l'INN par mesure directe et apport des nouvelles technologies

La mesure de l'INN va demander de connaître à la fois la biomasse sèche et le contenu en N de la végétation. Cela passe donc nécessairement par des prélèvements destructifs sur le terrain. Le dosage de l'N peut par la suite être réalisé en laboratoire par différentes méthodes (méthode Dumas, méthode Kjeldahl, etc.). Toutefois, malgré la précision et la fiabilité de la mesure, cela va entraîner une procédure destructive (prélèvement), chronophage et coûteuse qui n'est pas compatible avec une utilisation de l'INN dans le cadre du suivi de la culture en champ (Quemada et al., 2019, Aranguren et al., 2020). L'estimation indirecte de l'INN, par proxi- ou télédétection semble donc prometteuse et a pour avantages d'être rapide, non destructive, répétable et précise (Chen, 2015). En fonction des technologies utilisées, elle peut aussi être bon marché, avec un haut débit d'acquisition et prendre en compte l'hétérogénéité à l'échelle de la parcelle (Niu et al., 2019, Aranguren et al., 2020). Enfin, l'utilisation de capteurs pour estimer en temps réel le statut azoté des cultures serait un levier permettant d'adapter les pratiques de fertilisation et d'augmenter le NUE (Sharma et Bali, 2017).

2. Le suivi de l'INN par proxi- et télédétection

2.1. Les propriétés optiques du couvert en lien avec le statut azoté

2.1.1. Les propriétés optiques des feuilles

Selon plusieurs études, 50 à 55% de l'N contenu dans les feuilles est impliqué dans la photosynthèse, 25-30% dans les protéines non-photosynthétiques et les 20% restants sous une autre forme (dont la structure) (Hikosaka et Terashima, 1996 ; Lawlor et al., 1997 in Houlès et al., 2007). Le contenu en N des feuilles est donc fortement corrélé à la teneur en chlorophylle (Shepers et al., 1996 in Padilla et al., 2014). Ainsi, le statut azoté peut être estimé de façon indirecte en se basant sur les propriétés optiques des feuilles qui permettent d'évaluer la teneur en chlorophylle et ainsi, de façon indirecte, la teneur en N (Haboudane et al., 2002 ; Ercoli et al., 1993 in Baret et Fourty, 1997).

En effet, un rayon lumineux, en atteignant la feuille, est en grande partie absorbé pour la photosynthèse, le reste est réfléchi par la feuille, transformé sous forme de chaleur, transmis par transmittance ou en moindre mesure transformé en fluorescence (Figure 6 ; ministère de l'Agriculture, de l'Agroalimentaire et de la Forêt, 2017).




Figure 6 : Schéma du devenir de l'énergie d'un rayon incident atteignant la surface d'une feuille. La majeure partie du rayonnement est absorbé par la feuille pour la photosynthèse, le reste est réfléchi, transformé sous forme de chaleur, transmis par transmittance ou en moindre mesure transformé en fluorescence (ministère de l'Agriculture, de l'Agroalimentaire et de la Forêt, 2017)

2.1.2. Les longueurs d'onde impliquées dans les réactions

2.1.2.1. Transmittance

La transmittance va dépendre des parts de rayonnement absorbés et réfléchis, et donc de la composition de la feuille. D'après Baret et Fourty (1997), la transmittance est légèrement plus sensible aux variations de contenu en chlorophylle que la réflectance tout en ayant l'avantage d'être moins sensible aux autres facteurs, comme les propriétés réfléchissantes des feuilles. De plus, la mesure de la transmittance est une mesure stable à 2200nm qui est une bande de forte absorption des protéines (Baret et Fourty, 1997).

2.1.2.2. Fluorescence

La part de rayonnement émis par fluorescence chlorophyllienne est faible en comparaison avec le rayonnement émis par réflectance. Toutefois, il a l'avantage de n'être lié qu'à l'activité photosynthétique (Tremblay et al., 2011 ; Colaço et al., 2018). La fluorescence est induite par la réception d'un rayonnement ultraviolet (UV) et elle est liée au contenu en polyphénols des feuilles. Or, le contenu en flavonols est inversement corrélé au statut azoté. En effet, en cas de déficit azoté, la concentration en flavonols dans la feuille augmente (Ben Abdallah et al., 2016). De ce fait, la mesure de la fluorescence est adaptée à la détection de carences en N. D'après Samson et al. (2000) et Cadet (2008) (in Ben Abdallah et al., 2016), les variations de fluorescence permettraient de détecter des carences en N précoces avant même que des variations de réflectance et d'absorbance ne soient observées. Buschmann et al. (2007) ont mis en évidence qu'une feuille verte émet par fluorescence dans le rouge, autour de 685-690 nm et dans le NIR autour de 730-740nm.

2.1.2.3. Absorbance et réflectance

Le degré de réflectance et d'absorbance varie en fonction de l'état du couvert et notamment en fonction du contenu en N. Ainsi, plusieurs études se sont intéressées aux longueurs d'onde explicatives du statut azoté des feuilles. Le spectre de réflectance des feuilles peut être divisé en différentes portions en fonction des longueurs d'onde considérées : (i) le visible (VIS, entre 390 et 750nm), (ii) le proche infrarouge (NIR ou *Near Infrared*, entre 800 et 1000nm) et (iii) l'infrarouge à ondes courtes (SWIR ou *Short Wave Infra Red*, entre 1000 et 2500nm) (Figure 7).




Figure 7 : profil de réflectance des plantes et caractéristiques d'absorption de composés, dans le visible (VIS), le proche infrarouge (NIR) et l'infrarouge à ondes courtes (SWIR) (Kuska et al., 2018)

Dans le VIS, l'absorption est déterminée par la teneur en pigments (chlorophylles, caroténoïdes, xanthophylles) des feuilles (Kuska et al., 2018). Les plantes absorbent environ 90% du rayonnement dans ces longueurs d'onde, ainsi la réflectance d'une feuille est faible dans le visible particulièrement dans le bleu et le rouge (Knipling, 1970). Le profil de réflectance montre toutefois un premier pic de réflectance dans le vert (environ 550nm). Demetriades-Shah et al. (1990) ont mis en évidence une relation entre les longueurs d'onde réfléchies par les feuilles dans le RedEdge (entre 670 et 800nm) et le contenu en chlorophylle. Cette étroite portion du spectre correspond au pic de réflectance par les feuilles à la limite du VIS et du NIR (Maes et Steppe, 2019 ; Baret et Fourty, 1997 ; Haboudane et al., 2008). Cela est confirmé par le travail de Basso et al. (2015) pour lequel les indices de végétation

incluant une mesure dans le RedEdge étaient plus performants pour détecter un changement de statut azoté indépendamment du stress hydrique.

Au contraire, à partir de 800nm, dans le NIR, la réflectance est bien plus élevée : les plantes reflètent environ 50% du rayonnement (Knipling, 1970). Ce sont les liaisons biochimiques entre les atomes C, N, O ou H qui absorbent le rayonnement à des fréquences spécifiques et l'absorption de la chlorophylle est considérée comme nulle dans le NIR (Baret et Fourty, 1997). Ainsi, dans le NIR, c'est la structure des cellules du mésophylle et les cavités entre les cellules qui sont corrélées positivement avec le contenu en N des feuilles (Erdle et al., 2011 ; Knipling, 1970 ; Kuska et al., 2018). Le degré d'absorbance et de réflectance va varier en fonction du contenu en N de la culture, en cas de déficit en N, il y aura plus de réflectance dans le visible et surtout moins de réflectance dans le NIR (Padilla et al., 2018 ; Diacono et al., 2013).

Enfin, la réflectance dans le SWIR est principalement influencée par le contenu en eau et composés chimiques (Kuska et al., 2018).

2.1.3. Estimations à l'échelle du couvert

Il est avéré que la réflectance d'un couvert ne va pas être identique à la réflectance d'une feuille individuelle. Selon Knipling (1970), la réflectance d'un couvert sera plus faible, de 40 à 70% par rapport à une feuille seule.

Baret et Fourty (1997) mettent en évidence 4 variables dont dépend la réflectance d'un couvert :

- les propriétés optiques des feuilles, qui vont comme mentionné précédemment dépendre de sa teneur en pigments et en eau, mais aussi de l'espèce, de la variété, de la ou des cultures présentes dans le couvert, de l'apparition simultanée de carences (Basso et al., 2015) et de la difficulté à séparer les effets de stress biotiques et abiotiques (Kuska et al., 2018).
- la réflectance du sol, qui varie avec le type de sol, son humidité et son anfractuosités.
- la structure du couvert, qui va modifier la réflectance en fonction du positionnement et de l'orientation des feuilles, de l'ombrage créé par la végétation, de la taille des plantes, de la présence de fleurs ou de fruits (Knipling et al., 1970).
- des conditions de mesure et principalement de l'angle de mesure, des conditions lumineuses, de l'atmosphère (Demetriades-Shah et al., 1990).

Ces 4 variables mettent en évidence la difficulté d'isoler la réflectance liée au statut azoté du couvert des autres paramètres l'influencent. L'enjeu est donc d'identifier les longueurs d'onde sensibles au statut azoté et réduisant les facteurs de confusion avec les autres paramètres évoqués. Les indices de végétation combinant la réflectance dans différentes longueurs d'onde peuvent répondre à cette attente en minimisant les effets des autres facteurs tout en gardant une bonne sensibilité aux caractéristiques du couvert (Baret et Fourty, 1997 ; Demetriades-Shah et al., 1990).

2.2. Les indices de végétation

2.2.1. Principe et longueurs d'onde utilisées

Les indices de végétation (IV) ont été développés afin d'augmenter la sensibilité au changement de statut azoté tout en diminuant la variabilité due aux autres facteurs par rapport à l'étude individuelle des longueurs d'onde. Il s'agit de combiner entre elles les réflectances dans des longueurs d'onde définies par des opérations simples (ratios, différences, etc.) (Diacono et al., 2013 ; Padilla et al., 2018 ;

Yang et al., 2019). Les indices ont par la suite été améliorés en sélectionnant des bandes plus sensibles au statut azoté et en complexifiant les formulations pour améliorer la prédiction.

Les longueurs d'onde principalement utilisées sont le rouge et le NIR (Jinru et Su, 2017) ; le rouge car c'est dans cette longueur d'onde que la plante absorbe au maximum et le NIR car la différence de réflectance dans ces longueurs d'onde est importante entre une plante saine et une plante carencée. Le *Normalized Difference Vegetation Index* ou NDVI (Rousse et al., 1973, Tableau 1), qui combine la lumière réfléchie dans ces 2 longueurs d'onde, est l'indice de végétation le plus connu et le plus utilisé (Hansen et Schjoerring, 2003), ce qui met aussi en évidence l'intérêt de ces 2 longueurs d'onde.

2.2.2. Limites des IV et émergence de nouvelles combinaisons

Le NDVI est reconnu pour être fortement corrélé à la teneur en chlorophylle, toutefois il souffre des principales limites rencontrées par les IV, à savoir les problèmes de saturation à haut niveau de biomasse (LAI supérieur à 3) et la sensibilité à l'atmosphère (Erdle et al., 2011). Sachant que l'atmosphère affecte la réflectance dans le rouge, des IV ont été développés de façon à réduire leur sensibilité à l'environnement, ces IV, comme l'ARVI (*Atmospherically Resistant Vegetation Index*, Kaufman et Tanré, 1992) ou le GARI (*Green Atmospherically Resistant Vegetation Index*, Gitelson et al., 1996), utilisent la différence de réflectance entre le rouge et le bleu plutôt que le rouge (Jinru et Su, 2017). Une autre limite des IV est leur sensibilité à la réflectance du sol. Pour cela, des indices ont été développés en intégrant une constante afin de tenir compte de la réflectance du sol. Parmi ces indices se trouvent le SAVI (*Soil Adjusted Vegetation Index*, Huete, 1988), l'OSAVI (*Optimized Soil Adjusted Vegetation Index*, Rondeaux et al., 1996) et le GOSAVI (*Green Optimized Soil Adjusted Vegetation Index*, Sripada et al., 2005). Ils intègrent une constante de 0 à 1 en fonction des conditions de la parcelle ; proche de 1 il y a peu d'effet de l'environnement (Jinru et Su, 2017).

2.2.3. Amélioration des performances des IV

2.2.3.1. Longueurs d'onde

Plusieurs études mettent en évidence que les IV basés sur la mesure de la réflectance dans le NIR et le RedEdge semblent être plus performants pour détecter les changements de statut azoté (Basso et al., 2015 ; Argento et al., 2020 ; Zheng et al., 2018 ; Li et al., 2014). Cela a notamment été confirmé par les travaux de Zheng et al. (2018), qui ont calculé 19 IV différents en testant aléatoirement différentes longueurs d'onde parmi les longueurs d'onde suivantes : 490, 550, 671, 700 et 800nm. Leur travail a permis de mettre en évidence que l'IV le mieux corrélé au contenu en N des feuilles était le RDVI (*Reformed Difference Vegetation Index*, Reuveau et Breon, 1995) avec l'utilisation des longueurs d'onde 700 et 800nm ($R^2=0,73$). Les résultats des travaux d'Argento et al. (2020) vont également dans ce sens puisque l'IV le plus performant pour suivre le statut azoté parmi les 7 testés était le NDRE (*Normalized Difference Red Edge*, Barnes et al., 2000), calculé avec la réflectance dans le NIR (790nm) et le RedEdge (735nm). Les coefficients de détermination obtenus étaient de 0.80 et 0.75 pour l'N absorbé (contenu en N dans la plante) et l'INN. Enfin, les résultats de Li et al. (2014) soulignent que les indices intégrant la réflectance dans le RedEdge plutôt que dans le rouge sont plus précis dans la prédiction du statut azoté après émergence de l'épi.

Ainsi, la sélection des longueurs d'onde est primordiale. Selon Li et al. (2014) la sélection de longueurs d'onde optimales améliore la capacité de prédiction du statut azoté par les IV de façon significative. Il semblerait que la nature des longueurs d'onde utilisées dans les IV plutôt que leur nombre améliore l'efficacité de prédiction. Les résultats de Zheng et al. (2018) montrent que les IV utilisant 3 et 4 bandes ne sont pas plus performants que des IV à 2 longueurs d'onde si celles-ci sont optimales pour estimer le contenu en N des feuilles.

2.2.3.2. Formulation

Au-delà des bandes utilisées dans la construction des indices, leur formulation va également influencer la qualité de prédiction du statut azoté. Zheng et al., (2018) ont combiné entre elles 5 longueurs d'onde selon 19 formules d'IV connus, ils affirment également que pour des longueurs d'onde identiques, la formule (ratio, différences, etc.) employée va influencer la performance des IV.

Concernant la formulation, les premiers IV consistaient en des différences de réflectance pour deux longueurs d'onde. Leur calcul était simple mais le résultat était très dépendant des conditions de mesure. D'autres combinaisons ont par la suite été développées afin de réduire la sensibilité aux paramètres extérieurs. Bao et al. (2013) distinguent 4 catégories d'IV : (i) les ratios qui sont moins sensibles à l'effet sol comme le SR (*Simple Ratio*, Birth et al., 1968) et le GRVI (*Green Ratio Vegetation Index*, Gitelson et al., 2002) ; (ii) les différences normalisées qui varient entre 1 et -1. Ces indices, dont font partie le NDVI, le GNDVI (*Green Normalized Difference Vegetation Index*, Buschmann et al., 1993), le NDRE, sont très utilisés et présentent de bonnes corrélations aux paramètres biophysiques du couvert ; (iii) les indices dérivés qui permettent d'exacerber les caractéristiques spectrales, comme le RDVI ; (iv) les combinaisons d'indices parmi lesquels se retrouvent le NDRE/NDVI, le TCARI/OSAVI, etc.

2.2.4. Corrélations étudiées entre IV calculés à partir d'images drones et paramètres du blé

Des études cherchent à corrélérer les IV à différents paramètres du blé :

- l'INN (Argento et al., 2020 ; Chen, 2015 ; Gordillo-Salinas et al., 2021),
- la concentration en N des feuilles (%N) (Liu et al., 2016 ; Zheng et al., 2018 ; Niu et al., 2019),
- le contenu en N des feuilles (g par unité de surface) (Yao et al., 2010),
- la concentration en N dans la biomasse aérienne (%N) (Quemada et al., 2019; Gordillo-Salinas et al., 2021; Li et al., 2014 ; Chen, 2015),
- le contenu en N dans la biomasse aérienne (g par unité de surface) (Bao et al., 2013 ; Quemada et al., 2019 ; Yang et al., 2019 ; Argento et al., 2020),
- le contenu en N absorbé (N absorbé par la modalité fertilisée auquel est soustrait l'N absorbé par le témoin non fertilisé et divisé par la dose d'engrais apportée) (Argento et al., 2020),
- les paramètres de récolte (rendement, teneur en protéines, teneur en N des grains) (Quemada et al., 2019 ; Basso et al., 2015 ; Mengmeng et Noboru, 2017 ; Fu et al., 2020),
- la biomasse (Quemada et al., 2019 ; Chen, 2015 ; Fu et al., 2020 ; Gordillo-Salinas et al., 2021),
- des mesures prises par d'autres capteurs (LAI (Leaf Area Index) par Fu et al., 2020 et Chen, 2015).

Cependant, cette liste est loin d'être exhaustive et toutes ces études n'étudient pas les mêmes IV et n'utilisent pas forcément les mêmes longueurs d'onde pour les calculer.

Ainsi, les IV peuvent être classés en fonction des paramètres de la plante auxquels ils sont corrélés : les indices de structure (NDVI, OSAVI, MTVI, etc.) et les indices chlorophylliens (NDRE, OSAVI, TCARI, etc.). Plusieurs études mettent également en évidence que la combinaison d'indices de végétation permet d'augmenter la corrélation au statut azoté, notamment en combinant des indices de structure et des indices chlorophylliens (Gabriel et al., 2017).

Tableau 1: synthèse des IV présentés et formulation (NIR : réflectance dans le proche infrarouge, R : réflectance dans le rouge, B : réflectance dans le bleu, G : réflectance dans le vert)

Abréviation	Indice	Formule	Référence
NDVI	Normalized Difference Vegetation Index	$\frac{NIR - R}{NIR + R}$	Rousse et al., 1974
ARVI	Atmospherically Resistant Vegetation Index	$\frac{NIR - RB}{NIR + RB}$ avec $RB=R-\mu(B-R)$	Kaufman et Tanré, 1992
GARI	Green Atmospherically Resistant Vegetation Index	$\frac{NIR - (G - (B - R))}{NIR + (G - (B - R))}$	Gitelson et al., 1996
SAVI	Soil Adjusted Vegetation Index	$\frac{NIR-R}{NIR+R+l} \times (1+l)$	Huete, 1988
OSAVI	Optimized Soil Adjusted Vegetation Index	$\frac{NIR - R}{NIR + R + 0.16}$	Rondeaux et al, 1996
GOSAVI	Green Optimized Soil Adjusted Vegetation Index	$\frac{NIR - G}{NIR + G + 0.16}$	Sripada et al., 2005
RDVI	Reformed Difference Vegetation Index	$\frac{NIR - R}{\sqrt{NIR + R}}$	Reujean et Breon, 1995
NDRE	Normalized Difference Red Edge	$\frac{NIR - RedE}{NIR + RedE}$	Barnes et al., 2000
MTVI	Modified Triangular Vegetation Index	$1.2(1.2(NIR-G)-2.5(R-G))$	Haboudane et al., 2004
TCARI	Transformed Chlorophyll Absorption in Reflectance Index	$3 \times [(RedE-Red)-0.2 \times (RedE-Green) \times (RedE/Red)]$	Haboudane et al., 2002
SR	Simple Ratio	$\frac{NIR}{R}$	Birth et al., 1968
GRVI	Green Ratio Vegetation Index	$\frac{NIR}{G}$	Gitelson et al., 2002
GNDVI	Green Normalized Difference Vegetation Index	$\frac{NIR - G}{NIR + G}$	Buschmann et al., 1993

2.3. Utilisation de modèles non-paramétriques de prédiction

2.3.1. Limites des modèles paramétriques et principe des modèles non-paramétriques

Quand bien même l'estimation d'un paramètre est traditionnellement basée sur une seule variable explicative (modèle de régression paramétrique), des études s'intéressent à la capacité de prédiction de modèles de régression non-paramétriques permettant de combiner différents IV (Yang et al., 2019 ; Zheng et al., 2018). Cela est mis en évidence dans la synthèse faite par Berger et al. (2020), sur 125 études portant sur la prédiction du statut azoté des cultures par imagerie hyperspectrale (Figure 8). Les régressions paramétriques, qui sont des relations simples établies entre une variable explicative et un paramètre de la culture représentent 77% des modèles établis, parmi eux, les IV sont les principales variables explicatives utilisées dans ces modèles (81%) (Berger et al., 2020).

Toutefois, les régressions paramétriques souffrent de certaines limites, notamment la prise en compte d'une faible portion du spectre les rendant très spécifiques aux capteurs utilisés et aux conditions de mesures (stade, culture, variété, site, etc.) (Berger et al., 2020). Ce qui explique que plusieurs études mettent en avant la difficulté d'avoir un seul et unique IV capable de suivre l'évolution du statut azoté dans des situations variées de conditions de mesures, variétés, stades de croissance, etc. (Chen, 2015 ; Zheng et al., 2018 ; Liu et al., 2016).




Figure 8 : méthodes utilisées pour prédire le statut azoté des cultures à partir d'images hyperspectrales (prises par proxidtection, drone, avion, satellites ou en laboratoire). Résultat d'une synthèse faite par Berger et al. (2020) sur 215 études

Par opposition aux modèles paramétriques, qui se basent sur une relation connue entre différentes variables, les modèles non-paramétriques sont appropriés lorsque le prédicteur le plus adapté est inconnu et qu'il n'existe pas de fonction d'estimation connue. Ces modèles se basent sur le jeu de données mesurées pour construire le modèle d'estimation. Ils sont adéquats lorsque le nombre de variables d'entrée est conséquent, comme souvent dans le cas de données issues de la télédétection.

En prenant en compte plusieurs IV à la fois, ils devraient être moins spécifiques que les IV seuls et permettraient d'augmenter le nombre de longueurs d'onde explorées. Ceci comblerait alors les limites identifiées précédemment et devrait ainsi permettre d'améliorer le suivi de l'INN (Zheng et al., 2018 ; Yang et al., 2019 ; Li et al., 2014 ; Yao et al., 2015 ; Liu et al., 2016).

2.3.2. Démarche générale

La démarche suivie a pour objectif de définir le modèle (algorithme) le plus adapté pour établir des liens entre un ensemble de variables explicatives dans le but de prédire au mieux une variable réponse d'intérêt. Cette démarche se décompose en deux grandes étapes (Makowski et al., 2021) : une étape d'entraînement des modèles suivi d'une étape de validation. Cette seconde étape peut prendre différentes formes en fonction des jeux de données de validation utilisés.

Pour cela le jeu de données entier initial est divisé en deux sous-ensembles, une partie pour l'entraînement des modèles (entre 60 et 80% du jeu de données) et une partie pour la validation (la partie restante du jeu de données, entre 40 et 60%). La première étape d'entraînement consiste à construire les modèles et à ajuster leurs paramètres à l'ensemble du jeu de données d'entraînement. Les modèles sont ensuite validés, une première validation peut être faite par validation croisée (*cross-validation*), c'est-à-dire en utilisant le même jeu de données que pour la phase d'entraînement. Le jeu de données est divisé en sous échantillons, un de ses sous échantillons est mis de côté pour valider le modèle tandis que les échantillons restants sont utilisés pour ajuster le modèle. Cette opération est répétée plusieurs fois en sélectionnant d'autres sous-échantillons. Dans le cas où chaque sous-échantillon correspond à un individu cette validation croisée est désignée par le terme de « *leave-one-out* ». Les modèles sont ensuite validés avec le jeu de données de validation prévu pour cela. La validation des modèles va permettre de sélectionner le modèle le plus pertinent parmi les modèles construits, celui-ci pourra par la suite être testé sur un jeu de données indépendant (Figure 9, Makowski et al., 2021, Leroux, 2018).




Figure 9 : schéma du processus de construction et de validation des modèles non-paramétriques

2.3.3. Indicateur de validation des modèles

Le but principal des modèles étant de prédire les valeurs d'une variable d'intérêt dans de nouvelles situations, la validation est donc une étape indispensable qui permet de définir le modèle le plus performant pour un usage donné et de prouver si le modèle est fiable et pertinent (Makowski et al., 2021, Leroux, 2018). Cette étape permet également de prendre en considération le risque de surajustement qu'il peut y avoir lors de la construction des modèles. En effet, lorsque le modèle construit est complexe (structure complexe ou ajustement trop important), le risque est qu'il soit trop ajusté au jeu de données d'entraînement. Cela entraîne une diminution l'erreur de prédiction sur le jeu d'entraînement. Or une fois appliqué sur un autre jeu de données cela peut conduire à augmenter l'erreur de prédiction car le modèle est trop ajusté au jeu de données d'entraînement, ainsi un modèle précis lors de la phase d'entraînement ne signifie pas forcément qu'il le sera dans une autre situation (Makowski et al., 2021).

Un certain nombre d'indicateur peuvent être calculé pour valider les modèles (Makowski et al., 2021):

- Le coefficient de détermination (R^2 , Eq. 3) :

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (\text{Eq. 3})$$

Le coefficient de détermination représente le ratio entre la somme des écarts résiduels et la somme des écarts totaux. Avec n le nombre de mesures, y_i la valeur observée et \hat{y}_i la valeur prédite pour l'individu i , \bar{y} la moyenne des valeurs du jeu de données de validation. Plus le R^2 est proche de 1, meilleure est la prédiction.

- Le biais (Eq. 4) :

$$\text{biais} = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)}{n} \quad (\text{Eq. 4})$$

Le biais correspond à la moyenne des résidus, il permet d'évaluer si les prédictions sont précises, si le modèle a tendance à sous ou surestimer les prédictions. Plus le biais est faible, proche de 0, moins le modèle a tendance à sous ou surestimer. Attention cependant, car il s'agit d'une moyenne, ainsi un biais nul ne signifie pas des erreurs faibles, elles peuvent être élevées mais en moyenne égales à 0.

- L'erreur quadratique moyenne (RMSE, Eq. 5) :

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (\text{Eq. 5})$$

Le RMSE est la racine carrée de l'erreur quadratique, il renseigne sur la taille des erreurs de prédiction et s'exprime dans la même unité que la variable y . Le RMSE est l'indicateur à minimiser pour avoir un modèle intéressant.

Enfin, étant donné que les modèles sont construits à partir du jeu de données mesurées, plus le jeu de données est étoffé (années, sites, variétés et stades différents), plus le modèle entraîné sera robuste et la qualité de prédiction améliorée (Li et al., 2014).

2.3.4. Utilisation des modèles non paramétriques sur des données issues de télédétection

Les modèles non-paramétriques permettant de prendre en compte un grand nombre de variables d'entrée, ils sont adaptés aux données issues de mesures de réflectances prises dans différentes longueurs d'onde. Le modèle de régression non-paramétrique le plus connu est la régression linéaire multiple, dont l'ajustement se fait par les moindres carrés ordinaires (Makowski et al., 2021). Toutefois

cette méthode n'est pas adaptée lorsque les variables explicatives sont corrélées entre elles ce qui est le cas des IV, calculés à partir des mêmes longueurs d'onde (Yao et al., 2015). Pour pallier à cela, une possibilité consiste à réaliser une régression pénalisée, le principe de la pénalisation est de diminuer la variance des variables d'entrée sans trop augmenter le biais. L'avantage de cette méthode est qu'elle reste dans le cadre des modèles de régression linéaire et donc permet d'obtenir des coefficients de régression facilement interprétables (Makowski et al., 2021).

Une autre solution consiste à transformer les variables explicatives corrélées, en de nouvelles variables indépendantes entre elles, pour cela deux méthodes existent (Makowski et al., 2021 ; Berger et al., 2020) :

- les régressions en composantes principales (PCR), pour lesquelles les nouvelles variables indépendantes, appelées composantes, sont définies par une analyse en composantes principales (ACP).
- les régressions des moindres carrés partiels (PLS), dans ce cas les composantes sont définies de manière à être corrélées à la variable d'intérêt. Cette méthode permet de pallier au fait que les premières composantes définies par ACP ne sont pas toujours corrélées à la variable d'intérêt.

Ces premières méthodes constituent les modèles linéaires de régression non paramétriques. D'autres modèles non-paramétriques et non-linéaires existent, ces algorithmes constituent un ensemble de méthodes d'apprentissage machine (*machine learning*). Parmi ces modèles se trouvent les arbres et forêts aléatoires (RFR, *random forest regression*), les réseaux de neurones artificiels (ANN, *artificial neural networks*), les séparateurs à vaste marge ou machines à vecteurs support (SVM ou SVR, *support vector machines*) (Berger et al., 2020 ; Leroux, 2019).

- le principe des arbres de régression (variable d'intérêt quantitative) consiste en un empilement d'arbres de décisions, construits par méthode CART (Classification And Regression Tree, Breiman, 1984 in Makowski et al., 2021). A partir du jeu de données total celui-ci est divisé selon la variable explicative la plus discriminante, à l'issue de ce découpage, les 2 sous échantillons créés sont eux même divisés en sous-échantillons selon une autre variable. L'étape est répétée jusqu'à ce qu'il n'y ait plus de subdivision possible, en fixant un effectif seuil dans les sous-échantillons créés, ou en fixant un nombre de niveau seuil (Makowski et al., 2021). Les RFR consistent à combiner la méthode CART tout en effectuant un tirage aléatoire avec remise dans l'échantillon de départ pour créer de nouveaux échantillons (Makowski et al., 2021).
- les ANN s'inspirent du fonctionnement des réseaux de neurones des cerveaux. Les neurones forment un réseau, chaque neurone étant interconnecté aux neurones de la couche précédente et dont les sorties alimentent la couche suivante. Chaque neurone est caractérisé par une fonction de transition donnant une valeur qui viendra alimenter d'autres neurones. Le neurone combine les informations en entrée, il est capable de pondérer différemment certaines variables, la fonction d'activation permet ensuite de produire une sortie. Cela est répété couche par couche jusqu'à obtenir un résultat unique en sortie (Makowski et al., 2021 ; Chaire AgriTIC, 2018).
- les SVR sont des algorithmes dont le fonctionnement vise à rechercher un hyperplan venant diviser le jeu de données en différentes classes et en minimisant l'erreur de classification. L'entraînement du modèle se fait par itération en recherchant l'hyperplan optimal pour séparer les données. Ces modèles permettent des prédictions précises et cela même dans le cas de jeux de données d'entraînement de petite taille (Mountrakis et al., 2011).

Ces méthodes de régressions non-paramétriques et non-linéaires se sont développées car elles sont performantes et robustes, elles permettent de prendre en compte de très nombreuses variables d'entrée et peuvent aboutir à des algorithmes très complexes. La synthèse faite par Berger et al. (2020) met en évidence que les modèles non-paramétriques et non-linéaires permettent de meilleures estimations que les modèles linéaires non-paramétriques. Cependant ces modèles, permettant de prendre en compte un grand nombre de variables d'entrée sont parfois trop complexes les rendant sujets au surajustement (Berger et al., 2020 ; Makowski et al., 2021).

Parmi les études portant sur la prédiction du statut azoté avec des modèles non paramétriques construits à partir d'images prises par drone, Yang et al. (2019) ont comparé les capacités de prédiction de 3 modèles pour estimer le contenu en N du couvert (exprimé en $\text{kg N}\cdot\text{ha}^{-1}$). Ils mettent en évidence, d'une part, que les modèles combinant les IV et les réflectances sont plus performants et, d'autre part que les modèles testés présentaient de bons résultats : PLS (*Partial Least Squares Regression*) ($R^2_{\text{validation}}=0.72$), SVR (*support vector regression*) ($R^2_{\text{validation}}=0.75$), PSO-SVR (*Particle Swarm Optimization-based Support Vector Regression model*) ($R^2_{\text{validation}}=0.80$). Zheng et al. (2018) ont, quant à eux, testé 13 modèles de prédiction de la concentration en N des feuilles (%N) : à l'exception des arbres de régression, les modèles amélioraient la performance de prédiction par rapport aux indices seuls, la meilleure prédiction ayant été obtenue avec les modèles RF ($R^2=0,79$).

Pour conclure, la télédétection offre des possibilités intéressantes pour suivre le statut azoté du blé. Les IV, en combinant la réflectance dans différentes longueurs d'onde, permettent diverses applications. Toutefois, leurs performances semblent être fortement dépendantes des conditions de mesure : espèce, stade de croissance, protocole de prise de mesure, état des feuilles, carences autres que les carences en N (Gabriel et al., 2017). Ainsi, il est compliqué de dégager un IV qui soit le plus performant dans un large nombre de situations (Li et al., 2014). Certaines longueurs d'onde comme le NIR et le RedEdge ont pu être identifiées comme étant plus sensibles au statut azoté tout en restant plus stables face aux sources de variations externes. Enfin, l'utilisation de modèles de prédiction semble être une bonne alternative pour combiner des IV entre eux. Cela permet d'outrepasser les limites des IV étudiés seuls en étant moins spécifique, et de prendre en compte un nombre plus large de longueurs d'onde.

2.4. Mesures par proxidétéction

La proxidétéction consiste en une caractérisation de la végétation à partir de mesures directes se faisant au contact de la végétation ou à quelques mètres, que ce soit avec des capteurs venant pincer la feuille ou des appareils de mesure à faible distance au-dessus du couvert (manuels ou embarqués sur tracteur). En assurant un contact proche avec la plante, ces appareils ont pour avantage d'avoir une bonne corrélation avec le statut azoté (Gabriel et al., 2017) et lorsque les mesures se font à l'échelle de la feuille cela permet de ne pas avoir d'effet du sol et de réduire l'impact de l'environnement (Padilla et al., 2018).

Ces outils ne mesurent pas directement le statut azoté mais se basent sur différentes mesures optiques (Tableau 2). Certains outils proposent de relier des mesures optiques à la teneur en chlorophylle et par corrélation au contenu en N des feuilles, comme c'est le cas pour le Dualex (Force A, Orsay, France) (Cerovic et al., 2012). D'autres outils cherchent à calculer des indices de végétation reliés au statut azoté, comme c'est le cas pour le Greenseeker (Trimble, Sunnyvale, Californie, États-Unis) qui calcule le NDVI. Les appareils peuvent être passifs en mesurant la réflectance de la lumière naturelle ou actifs en mesurant la lumière réfléchie à partir d'un rayonnement induit par l'appareil dans une longueur d'onde définie. L'avantage des capteurs actifs est qu'ils sont utilisables quelles que soient les

conditions de mesure. Pour les capteurs passifs, certains sont équipés de capteurs du rayonnement incident afin de prendre en compte les conditions de mesures.

Tableau 2 : Exemples d'outils de mesures utilisés en proxidtection et leurs caractéristiques

Outil	Société	Méthode de mesure	Longueurs d'onde utilisées (nm)
Dualex	Force A (Orsay, France)	Transmittance et fluorescence	375, 650, 710, 850
N-tester	Yara (Oslo, Norvège)	Transmittance	650, 960
N-sensor	Yara (Oslo, Norvège)	Réflectance (actif)	670, 730, 760
GreenSeeker	Trimble (Californie, États-Unis)	Réflectance (actif)	650, 770
Crop Sensor Isaria	Class (Harsewinkel, Allemagne)	Réflectance (actif)	4 longueurs d'onde de 660 à 780
RapidScan CS-45	Holland Scientific (Lincoln, États-Unis)	Réflectance (actif)	670, 730, 780

Padilla et al. (2018) identifient 3 types de capteurs :

- (i) les appareils de mesure de la teneur en chlorophylle par transmittance et/ou en moindre mesure par réflectance de la feuille, dans les longueurs d'onde dans le rouge (où la chlorophylle absorbe) et dans le NIR où la chlorophylle transmet (Padilla et al., 2018). La plupart des appareils de mesure se basent essentiellement sur des mesures de transmittance plutôt que de réflectance car cette première est moins sensible aux facteurs extérieurs comme les propriétés réfléchissantes de la surface des feuilles. L'inconvénient de ces outils est qu'ils peuvent saturer à des hauts niveaux de chlorophylle (Padilla et al., 2018) et être impactés par d'autres facteurs (ex : état des feuilles, des carences en éléments autres que l'N, etc.) (Gabriel et al., 2017). Ainsi, certains outils se basent également sur la mesure d'autres pigments comme les polyphénols qui sont inversement corrélés au statut azoté. La prise en compte de la teneur en chlorophylle et en polyphénols permet d'avoir une relation au statut azoté plus stable que le suivi seul de la chlorophylle (Cartelat et al., 2005 in Gabriel et al., 2017). La pince N-tester de Yara (Oslo, Norvège) est un exemple de capteur basé sur la transmittance tandis que le Dualex (Force A, Osay, France) se base sur une estimation de la concentration en chlorophylle par transmittance et de la teneur en flavonol par fluorescence.
- (ii) les capteurs mesurant la réflectance. Ils se basent sur des mesures de la lumière réfléchi par le couvert dans des longueurs d'onde définies et sont placés jusqu'à 3m au-dessus du couvert (Padilla et al., 2018). Les longueurs d'onde utilisées sont choisies pour être sensibles au changement de statut azoté et les combinaisons de longueurs d'onde sont privilégiées pour réduire la variabilité. L'IV majoritairement utilisé dans les outils commercialisés est le NDVI, ensuite en fonction des cultures des IV plus spécifiques peuvent être utilisés (s'il faut séparer l'effet sol de la culture par exemple) (Padilla et al., 2018). Le Greenseeker (Trimble, Sunnyvale, Californie), le Crop Sensor Isaria (Class, Harsewinkel, Allemagne), RapidScan CS-45 (Holland Scientific, Lincoln, États-Unis) et le N-Sensor (Yara, Oslo, Norvège) sont des exemples d'outils se basant sur des mesures de réflectance en proxidtection à l'aide de capteurs multispectral. L'étude de Berger et al. (2020) portant sur l'utilisation des caméras hyperspectrales pour le suivi du statut azoté des cultures, met également en évidence que ces caméras sont principalement utilisées pour réalisées des mesures de réflectances par proxidtection. En effet, sur les 167 études analysées 75% étaient réalisées en utilisant des spectro-radiomètres,

principalement de type ASD (Analytical Spectral Devices) avec des mesures de réflectance dans les longueurs d'onde de 350 à 2500nm.

- (iii) les appareils de mesure du contenu en flavonols se basent sur la fluorescence. Ces capteurs se basent sur des mesures de fluorescence sous l'incidence d'un rayon dans le rouge et dans les UV (Figure 10). En effet, la fluorescence induite sous rayonnement UV varie lors d'un stress azoté, alors qu'elle n'est pas impactée par une excitation dans le rouge. Ainsi, en comparant le rayonnement émis par fluorescence après excitation dans le rouge et les UV il est possible d'estimer le contenu en flavonols (Padilla et al., 2018).




Figure 10 : Principe de mesure du contenu en flavonols par fluorescence (Padilla et al., 2018)

Des études ont comparé les performances de différents outils de proxidtection. C'est par exemple le cas de Quemada et al. (2019) qui ont travaillé avec un Dualex (Force A, Orsay, France) et un Greenseeker (Trimble, Californie, États-Unis) sur la culture de blé. Le Dualex propose d'estimer le contenu en chlorophylle de la feuille par différence de transmittance dans le rouge (710 nm, absorption par la chlorophylle) et le NIR (850 nm, référence) (Padilla et al., 2018). Tandis que le contenu en flavanols est défini en comparant la fluorescence chlorophyllienne émise sous excitation dans le visible (650nm) et les UV (375nm) (Padilla et al., 2018). Le ratio entre le contenu en chlorophylle et en flavonols, permet de calculer le Nitrogen balance index (NBI), un indicateur du statut azoté. Celui-ci prenant en compte deux pigments présentant des corrélations opposées à la concentration en N, permettrait d'être plus sensible aux changements de statut azoté qu'une estimation basée sur un seul composé (Cartelat et al., 2005).

Les résultats obtenus par Quemada et al. (2019) concernant l'INN varient en fonction des stades. A mi-élongation (GS34), le Dualex permet une meilleure estimation de l'INN ($R^2=0,51$ entre l'INN et le NBI calculé à partir de mesures du contenu en pigment mesuré au Dualex, contre 0,29 entre le NDVI mesuré au Greenseeker et l'INN). Au stade floraison (GS65) les différences entre les outils sont peu marquées ($R^2=0,54$ pour le Dualex et 0,56 pour le Greenseeker). Aranguren et al. (2020) ont, quant à eux évalué la capacité de prédiction de l'INN par la pince N-Tester (Yara, Oslo, Norvège) et le Rapid-Scan CS-45 (Holland Scientific, Lincoln, États-Unis). Leurs résultats sur blé mettent en avant que le NDVI calculé à partir des mesures faites au Rapid-Scan CS-45 (réflectance à 670, 730 et 780nm) permet la

meilleure estimation de l'INN (meilleur $R^2=0.75$ obtenu à épis 1cm), les relations obtenues avec le N-Tester ne seraient pas significatives (résultats non représentés).

2.5. Mesures par télédétection

La télédétection consiste à mesurer la lumière réfléchi à distance avec des capteurs embarqués sur des vecteurs aériens (drones et avions) ou satellites. Deux avantages majeurs de la télédétection sont, d'une part, sa capacité à couvrir une surface plus ou moins importante et, d'autre part, sa capacité à pouvoir prendre en compte la variabilité spatiale des besoins en N.

Le suivi de l'INN par télédétection permet d'estimer, de façon indirecte, la biomasse et le contenu en N des cultures en se basant sur le suivi du ratio absorbance/réflectance du couvert qui varie en fonction du statut azoté de la culture (Aranguren et al., 2020). Le suivi par télédétection des cultures peut être caractérisé par une caméra et un vecteur utilisé pour supporter cette caméra, chaque ensemble ayant une caractéristique spectrale et spatiale propre.

2.5.1. Vecteurs

En France, les satellites sont les vecteurs les plus utilisés (85% des surfaces agricoles télédéteectées) suivis par les drones et les avions (15% des surfaces agricoles télédéteectées) (Lachia, 2020). Les grandes différences entre eux sont la résolution spatiale de leur capteurs optiques, la surface couverte, la flexibilité d'utilisation et le coût pour l'utilisateur (Tableau 3).

La résolution spatiale, qui correspond à la dimension du plus petit élément que le capteur est capable de détecter, d'un satellite est de l'ordre du mètre. Les satellites Sentinel-2, par exemple, sont en orbite à 786km d'altitude pour une résolution spatiale de 10 à 60m selon les capteurs (CNES, 2017), ce qui veut dire que la plus petite image satellite Sentinel-2 correspond à une surface de 10m x 10m (100m²) au sol. Au contraire, la résolution spatiale d'un système d'imagerie drone est de l'ordre du centimètre. Bollas et al. (2021) ont comparé ces 2 vecteurs à travers la mesure du NDVI en 15 points et à 5 dates de mesure. Le NDVI était calculé, d'une part, à partir des images Sentinel-2 et, d'autre part, à partir de mesures faites par une caméra Sequoia Plus (Parrot, Paris, France) embarquée sur un drone eBee SQ (SenseFly, Cheseaux-sur-Lausanne, Suisse) avec une résolution spatiale de 0,13m. Qu'il soit calculé à partir d'images prises par drone ou par satellite, le NDVI suivait la même tendance et les corrélations entre le NDVI, calculé par drone, et celui calculé par satellite étaient fortes avec un R^2 de 0,84 à 0,97. Toutefois, l'étendue des valeurs de NDVI et le coefficient de variation sont plus importants pour les mesures par drone que par satellite. Ainsi, le drone est plus adapté dans les zones à forte hétérogénéité et pour piloter des interventions localisées. De plus, le drone a pour avantage d'offrir une flexibilité d'utilisation : choix de la caméra, de la fréquence d'acquisition d'images, de la résolution spatiale, peu de sensibilité à la couverture nuageuse (Shirrmann et al., 2016). Néanmoins, il couvre une surface réduite (en fonction de l'autonomie de la batterie) par rapport au satellite (Alvarez-Vanhard et al., 2021 ; Jinru et Su, 2017 ; Jiang et al., 2019 ; Späti et al., 2021). Au contraire, l'acquisition d'images satellites est moins flexible et va être dépendante du temps de résolution de celui-ci, ce qui rend ce vecteur peu adapté dans le cas de suivis fréquents, d'autant plus qu'en fonction de la couverture nuageuse les images ne sont pas forcément exploitables (Manfreda et al., 2018 ; Zheng et al., 2018 ; Späti et al., 2021). Toutefois, la régularité de la prise de mesure sur le long terme permet d'acquérir un nombre de données conséquent et de faire des comparaisons entre années (Jinru et Su, 2017 ; Späti et al., 2021). Pour l'utilisateur, travailler sur des images satellites sera plus facile et moins onéreux que des images drone. En effet, le drone nécessite l'acquisition du matériel, la formation au pilotage et un traitement d'images plus fastidieux et coûteux nécessitant des logiciels spécialisés (Jinru et Su, 2017 ; Yang et al., 2019 ; Manfreda et al., 2019 ; Späti et al., 2021). Cependant, certaines études mettent en évidence que l'utilisation du drone est plus économique lorsque la surface étudiée est réduite (Matese

et al., 2015 ; Zheng et al., 2018). Le coût total d'une analyse du NDVI reviendrait à 400 €.ha⁻¹ pour un champ de 5ha survolé par drone, contre 30% de plus pour un NDVI issu d'images satellite (Matese et al., 2015). Pour conclure, ces 2 vecteurs sont performants et adaptés à des usages différents en fonction de l'utilisation des données (Bollas et al., 2021 ; Alvarez-Vanhard et al., 2021).

Tableau 3 : synthèse des principales caractéristiques des drones et satellites (d'après Späti et al., 2021 et Lachia 2020)

	Drone	Satellite
Résolution spatiale	Elevée : en fonction du capteur et de la hauteur de vol de quelques cm à 2m×2m	Insuffisante selon certains usages : une à plusieurs dizaines de mètres (10m×10m pour Sentinel2)
Acquisition d'images	Souplesse de mise en œuvre et possibilité d'avoir sa propre plateforme (choix hauteur de vol, caméra, dates de survols) Mais survols restreints par la réglementation	Facilité d'accès, volume conséquent d'images et bonne résolution temporelle
Fréquence de prise de mesures	Flexibilité : souplesse de mise en œuvre et possibilité d'avoir sa propre plateforme Mais restreint par la réglementation	Flexibilité moindre : fréquence dépendante de la résolution du satellite
Dépendance aux conditions climatiques	Moins dépendant et affecté par les conditions atmosphériques que les satellites, mais sensible au vent et à la pluie	Forte dépendance aux conditions climatiques (couverture nuageuses)
Surface couverte	Faible, dépendance à l'autonomie de la batterie	Grande
Coût des images	Coûteuses : nécessite un traitement d'image avec des logiciels spécialisés, la formation...	Peu coûteuses

2.5.2. Caméras

Concernant les caméras utilisées en télédétection, elles peuvent être regroupées en 5 catégories :

- (i) Les caméras RGB qui mesurent la réflectance dans le rouge (R, entre 622 et 780 nm) vert (G, entre 577 et 492 nm) et bleu (B, entre 455 et 492nm). Elles ont pour avantages de permettre une bonne résolution spatiale et d'être bon marché mais elles ont une faible résolution spectrale comparée à d'autres caméras (Jiang et al., 2019).
- (ii) Les caméras RGB modifiées qui améliorent la résolution spectrale en augmentant la sensibilité dans le NIR (700 à 1600nm) d'une simple caméra RGB.
- (iii) Les caméras modulables, qui sont plus flexibles et permettent à l'utilisateur de combiner des objectifs différents et/ou de changer les filtres en fonctions des usages. Les caméras Airphen (Hiphén, Avignon, France), Kernel (Mapir, San Diego, USA) en sont des exemples. Ces 3 premières catégories de caméras correspondent aux caméras dites multispectrales.

- (iv) Les caméras hyperspectrales ont une résolution spectrale encore plus fine et peuvent couvrir l'ensemble du spectre de 400 à 1000nm avec des intervalles faibles entre les longueurs d'onde mesurées. Toutefois ces caméras ne sont pas toujours compatibles avec les drones.
- (v) Les caméras thermiques, qui permettent de mesurer les longueurs d'onde comprises entre 7000 et 12000 nm et permettent d'avoir la température du couvert (Maes et Steppe, 2019).

Quels que soient les capteurs ou vecteurs utilisés, plusieurs travaux mettent en garde sur le fait que les résultats sont fortement dépendants des sites, mais également des stades (Argento et al., 2020). Enfin, les outils commercialisés varient entre eux en fonction des longueurs d'onde utilisées, du procédé de calibration, de la transformation de la mesure vers un indice ou une valeur de conseil en fonction de l'espèce pour laquelle les mesures ont été développées, du protocole de mesure (nombre d'échantillon, surface couverte, etc.) (Padilla et al., 2018). Ainsi différents chercheurs travaillent sur l'amélioration de la prédiction du statut azoté par drone dans des contextes définis (ex : choix des IV, test de capteurs, identification de longueurs d'onde d'intérêt, identification de stades d'intérêt, tests de différents modèles de prédiction) ou en corrélant des mesures prises par télédétection avec des mesures de terrain, de rendement ou des modèles de croissance des cultures (Niu et al., 2019 ; Zheng et al., 2018 ; Gordillo-Salinas et al., 2021 ; Argento et al., 2020 ; Quemada et al., 2019).

2.5.3. Traitement des images prises par un drone

L'obtention d'images de qualité va débiter dès la préparation du vol. Comme évoqué précédemment, les images acquises par drone ne pourront pas être directement exploitées mais nécessitent un processus de traitement. L'ensemble du processus d'acquisition et de traitement des images est schématisé en Figure 11.




Figure 11 : Schéma des étapes d'acquisition et de traitement d'images prises par drone

Indépendamment de la caméra, la préparation avant le vol va influencer la qualité des images. Par exemple, le choix de la hauteur de vol va agir sur la résolution de l'image. De mauvaises conditions de vol et le choix de l'angle des passes peuvent également être à l'origine d'images floues (Manfreda et al., 2018). Le pourcentage de recouvrement entre les images, permettant par la suite de combiner les images, va également être défini lors de cette étape.

Pendant l'acquisition d'images, il est important d'assimiler les valeurs de position et d'orientation de chaque image qui seront des informations essentielles lors de l'analyse. Les coordonnées des images sont acquises par un récepteur GNSS embarqué (*Global Navigation Satellite System*) tandis que la position et l'orientation au sol sont déterminées par la centrale inertielle ou IMU (*Inertial Measurement Unit*). La précision de ces données peut être améliorée en utilisant en complément une cible dont les coordonnées sont connues (Aasen et al., 2018 ; Manfreda et al., 2018).

Avant d'être analysées, les images doivent tout d'abord être calibrées et corrigées. La calibration radiométrique et les corrections vont permettre d'obtenir une valeur de réflectance normalisée par pixel et ainsi identique durant la totalité du vol afin de prendre en compte les variations d'illumination pouvant avoir lieu pendant et entre les vols (Aasen et al., 2018 ; Manfreda et al., 2018). La calibration peut se faire à partir de cibles dont la valeur de réflectance par longueur d'onde est connue. Ces cibles sont appelées mires de calibration. Cette mire de calibration est prise en photo avant et après chaque vol. Dans d'autres cas, la caméra est équipée d'un capteur du rayonnement incident pour la calibration. Cette solution facilite le traitement d'images mais peut également être à l'origine de biais (Manfreda et al., 2018). Parmi les corrections se retrouvent aussi la correction du bruit (signal indésirable produit par le capteur), du vignettage (différence d'intensité entre le centre et la périphérie de l'image) et de la distorsion de l'objectif (Jiang et al., 2019). Les deux premières corrections se font par le calcul de coefficients de correction tandis que la distorsion d'objectif se corrige par le modèle de Brown (Jiang et al., 2019). Par la suite, les images individuelles doivent être regroupées afin d'obtenir une orthoimage, c'est-à-dire une vue aérienne de la zone survolée superposable sur une carte. La combinaison des images individuelles se fait par superposition grâce aux similitudes entre les images, rendue possible par le pourcentage de recouvrement déterminé avant le vol (environ 75%). Après ces étapes, les valeurs d'intérêt peuvent être extraites pour calculer des IV.

3. Enjeux de la gestion de l'azote

3.1. La fertilisation azotée minérale et les enjeux associés

Afin de satisfaire les besoins alimentaires de la population mondiale en croissance accélérée, l'utilisation mondiale d'engrais azotés a augmenté considérablement depuis les années 1950 (Vance, 2001), avec actuellement une croissance annuelle de 1.5% (FAO, 2019). En effet, à partir du XXème siècle, la mise au point du processus Haber-Bosch a permis de synthétiser de l'ammoniac à partir de diazote (N_2) et de dihydrogène (H_2). Cette avancée technologique a entraîné la production massive d'engrais azotés minéraux (Cellier, 2019 ; Pellerin et al., 2014). A partir de cette période, l'N qui était jusqu'à lors un élément limitant, est devenu disponible en grandes quantités. Il peut être apporté pour couvrir les besoins des cultures, allant souvent jusqu'à être apporté en excès. Le cycle de l'N lui-même s'en retrouve alors impacté. Bien qu'auparavant il était nécessaire de recycler l'N organique pour assouvir les besoins des cultures, la disponibilité en engrais azotés de synthèse a fait changer le paradigme de raisonnement de la fertilisation (Pellerin et al., 2014). Il faut dès lors chercher à optimiser la fertilisation azotée afin de combiner productivité, économie et prise en compte de l'environnement.

La fertilisation azotée est au cœur de différents enjeux mis en avant par le Comité Français d'Etude et de Développement de la Fertilisation Raisonnée (Comifer, 2013) :

- Premièrement, un enjeu de productivité peut être discuté, une synthèse faite entre 1991 et 2007 par les organismes économiques et de développements agricoles mettent en évidence qu'en absence d'apport d'engrais, les pertes peuvent aller de 0 à 90 % de la production maximale. Pour un apport de 200 kg N.ha⁻¹, la production atteint de 80 à 100% de la production maximale (Comifer, 2013). Ces résultats mettent en évidence l'enjeu que représente la fertilisation pour maximiser la production mais aussi l'importance de raisonner les apports afin de prendre en compte les fournitures du sol.
- Deuxièmement, la fertilisation représente un enjeu pour la qualité des récoltes. En effet, la teneur en protéines est un critère qualitatif particulièrement important en blé et celui-ci va notamment définir le débouché de la récolte (Brown et al., 2005). Les marchés, de plus en plus concurrentiels, incitent les producteurs à conserver une teneur en protéine supérieure à 11,5%.
- Le troisième enjeu est la préservation de la qualité de l'eau et de l'air. En effet, la surfertilisation peut induire des pertes vers les eaux pour les formes d'N solubles ou vers l'atmosphère pour les formes gazeuses. D'après le rapport de l'« *European nitrogen assesment* » (Sutton et al., 2010), les excès d'N seraient à l'origine de 5 problèmes majeurs parmi lesquels (i) une dégradation de la qualité des eaux souterraines et de surface (ex : eutrophisation, acidification, etc.) et (ii) de l'air (ex : émissions de NO_x, de dioxyde d'N, etc.). De ces pollutions découlent également d'autres dangers environnementaux : (iii) une augmentation de l'effet de serre (émission de N₂O), (iv) un impact sur l'écosystème et la biodiversité (lié aux pollutions des milieux et à la création d'un déséquilibre) et (v) une dégradation de la qualité des sols (Bibi et al., 2016 ; Cellier, 2019).

Un des défis majeurs de l'activité agricole actuelle est donc de concilier les nécessités d'une agriculture productive, compétitive et de qualité avec le maintien et l'amélioration du milieu environnant. Le Comifer met également en avant des enjeux de la fertilisation sur la performance énergétique et le changement climatique. Dans ce contexte, le concept de raisonnement de la fertilisation a émergé, il s'agit d'ajuster les apports d'engrais minéraux ou organiques en fonction des besoins de la culture pour

répondre à un objectif de production tout en prenant compte les fournitures d'N présentes dans le sol (Comifer, 2013).

3.2. Pilotage actuel de la fertilisation

3.2.1. La méthode du bilan

3.2.1.1. *Origines*

La méthode du bilan a été développée pour ajuster la dose d'engrais minéral à apporter aux besoins de la culture afin d'atteindre un objectif de production tout en prenant compte des fournitures d'N du sol. L'objectif de cette méthode est de permettre une nutrition non limitante de la culture tout en minimisant les pertes vers l'environnement (Ravier et al., 2016).

Le développement du concept de bilan minéral a été développé dès 1969 par Hébert (Hébert, 1969 in Meynard et Jeuffroy, 2019). Depuis lors, le principe général continue d'être appliqué tandis que la modélisation et le calcul des différents termes et équations ont été affinés. En 1978, la méthode va être vulgarisée et dans les années 90 les premières variantes locales vont apparaître (Meynard et Jeuffroy, 2019).

3.2.1.2. *Raisonnement*

L'objectif de ce bilan azoté est d'équilibrer les besoins en N de la culture et les fournitures en calculant une dose totale d'N minéral à apporter pour combler cet écart. Le bilan d'N minéral du sol est calculé pour une période donnée et correspond à la différence entre l'état final et l'état initial soit les entrées auxquelles sont soustraites les sorties.

L'équation de la dose à apporter, la dose bilan, est la suivante :

$$\text{Dose} = \text{Besoins} - \text{Fournitures} + \text{Pertes} = (\text{Pf} + \text{Rf}) - (\text{Mh} + \text{Mr} + \text{Mhp} + \text{MrCi} + \text{Pi} + \text{Ri} + \text{Nirr} + \text{Fs} + \text{Np}) + \text{L} + \text{G} \quad (\text{Eq. 6})$$

Dans laquelle : Pf = quantité d'N absorbée à la fermeture du bilan ; Rf = quantité d'N minéral à la fermeture du bilan (équivalent au reliquat d'N minéral dans le sol à la récolte) ; Mh = minéralisation de l'humus, Mr = minéralisation des résidus, Mhp = minéralisation des résidus engendrée par une ancienne prairie, MrCi = minéralisation des résidus de culture intermédiaire, Pi = quantité d'N absorbé par la culture à l'ouverture du bilan, Ri = quantité d'N minéral dans le sol à l'ouverture du bilan (équivalent au reliquat d'N minéral à la sortie de l'hiver), Nirr = irrigation, Fs = fixation symbiotique, Np = pluie, L = lixiviation, G = volatilisation.

Le besoin en N est défini par l'objectif de rendement. Il est calculé à partir du besoin de la culture par unité de rendement (b), celui-ci est dépendant de l'espèce. Ce besoin est multiplié à l'objectif de rendement, qui correspond à la moyenne des rendements obtenus sur les 5 dernières années dans un même contexte en excluant les 2 années extrêmes (Eq. 7).

$$\text{Pf} = \text{besoin de la culture (b)} \times \text{objectif de rendement (y)} \quad (\text{Eq. 7})$$

Dans la pratique, la méthode du bilan est utilisée sur une période allant de la sortie de l'hiver à la récolte, cela permet de ne pas inclure dans le calcul les pertes par lixiviation pouvant avoir lieu durant la période de drainage (hiver) et par minéralisation automnale. Ainsi les valeurs Ri correspondent généralement au reliquat sortie hiver et Rf au reliquat post-récolte. Le Ri est le seul poste de la méthode du bilan à être mesuré, les autres postes sont calculés ou estimés à partir des caractéristiques de la parcelle (conditions pédoclimatiques, précédent cultural, itinéraire technique, etc.) (Comifer, 2013). Ainsi, malgré une rigueur scientifique dans l'élaboration des termes de la méthode, celle-ci peut être source d'imprécision dans la pratique lorsque les caractéristiques de la parcelle sont méconnues ou mal appliquées (Ravier et al., 2016).

3.2.1.3. Applications

Le développement de la méthode du bilan a permis de simplifier la planification des apports dans le sens où une fois les paramètres validés en fonction du contexte, il n'est pas nécessaire de mettre en place un réseau d'essai pour définir la dose à apporter. Ce raisonnement, basé sur des termes scientifiques tout en étant un outil de terrain, a permis à la méthode du bilan de se démocratiser jusqu'à être adoptée en France, en 2011, comme outil réglementaire dans le cadre de la Directive Nitrates (2011, articles R.211-75 à R.211-84 du code de l'environnement) (Meynard et Jeuffroy, 2019).

En pratique, en cours de campagne la dose prévisionnelle calculée à partir de la méthode du bilan va être fractionnée en 3 ou 4 apports (90% des situations, Degan et al., 2009). Cela va permettre de synchroniser les dates et doses d'apports aux besoins en N de la culture afin de maximiser leur valorisation et ainsi contribuer à augmenter le NUE (Sharma et Bali, 2017). Les dates d'apport sont généralement calées sur des stades-repères de la culture pour correspondre à sa cinétique d'absorption de l'N. De façon générale, les apports sont réalisés : aux stades tallage, épis 1cm et entre le stade 2 nœuds et gonflement (Figure 12). En moyenne, 30% de la dose totale est apportée au 1^{er} apport, 45% au 2^{ème} et 25% lors du 3^{ème} apport (Degan et al., 2019). L'apport au stade tallage, correspondant à la sortie hiver, est limité car les besoins à ce stade sont encore peu importants. Au stade épis 1cm, le blé entame la phase de montaison caractérisée par une augmentation marquée des besoins en N, il s'agit donc de l'apport le plus conséquent. Enfin le dernier apport a pour principal objectif d'augmenter la teneur en protéines des grains. Toutefois les apports réalisés en fin de cycle sont mieux valorisés que les apports réalisés au cours des premiers stades en sortie d'hiver (Sieling et Beims, 2007). Les travaux de Seiling et Kage (2021) illustrent ce résultat par l'étude des coefficients apparents d'utilisation de l'azote de différentes variétés à 3 dates d'apports. En fonction des variétés, ceux-ci atteignent au maximum 62% en sortie hiver, 77% en début d'élongation, et 82% à l'émergence de l'épis.




Figure 12 : schéma du fractionnement de la dose totale d'azote en trois apports en fonction du stade de croissance de la culture de blé (Arvalis, 2014)

3.2.1.4. *Limites*

La fertilisation azotée est une pratique encadrée. La Directive Nitrates est une directive européenne (directive 91/676/CEE) qui a été établie en 1991 dans le but de réduire les pollutions par les nitrates d'origine agricole. Mais, malgré les progrès réalisés pour affiner le calcul de la dose bilan, la surfertilisation et les pollutions par les nitrates d'origine agricole sont toujours d'actualité. En 2017, le seuil de 10 mg.L⁻¹, correspondant à la présence naturelle des nitrates dans les nappes, est dépassé dans 60% des eaux souterraines. Le seuil de potabilité de 50 mg.L⁻¹ est quant à lui encore dépassé dans 4% des masses d'eau souterraines du premier niveau (au plus près du sol) (Ministère de la transition écologique et solidaire, 2017). Par manque d'amélioration de la qualité des masses d'eau, la directive nitrates a intégré en 2013 l'obligation de calculer la dose bilan à partir d'une analyse de sol. Des GREN (Groupe Régional d'Expertise Nitrates) ont été mis en place en région pour adapter la méthode au contexte régional.

L'application de la méthode du bilan comporte des limites. Un des points de controverses est l'utilisation d'un objectif de rendement comme base pour calculer les besoins de la culture. En théorie il s'agit de la moyenne des rendements obtenus sur les 5 dernières années dans un même contexte en excluant les 2 années extrêmes. Au-delà du fait que cet objectif n'est pas toujours bien défini par les agriculteurs dans la pratique (Ravier et al., 2016), Meynard et Jeuffroy (2019) mettent en avant d'autres limites : le risque de ne pas atteindre le rendement potentiel les années favorables, une mauvaise valorisation du progrès génétique et le risque de voir les rendements stagner. Enfin, se baser sur l'objectif de rendement défini en amont de la campagne ne permet pas de prendre en compte les conditions climatiques du printemps qui agissent sur la production.

Au-delà des limites liées à son utilisation, de récentes études ont mis en évidence que certaines connaissances sur la fertilisation ne sont pas valorisées dans la méthode du bilan (Ravier et al., 2016 ; Ravier et al., 2017a). En effet, la notion de carences tolérables et de l'augmentation de l'efficacité des apports lorsqu'ils sont décalés ne sont pas prises en compte.

3.2.1.5. *Perspectives*

Dans le but d'atteindre un objectif de production, à la fois quantitatif et qualitatif, tout en tenant compte des enjeux environnementaux de la fertilisation azotée, la méthode du bilan s'est développée et imposée comme la méthode de référence, jusqu'à être intégrée à la réglementation. Toutefois, malgré sa rigueur scientifique son application présente des limites. Afin d'augmenter l'efficacité des apports azotés, plusieurs études montrent que la fertilisation doit être revue en intégrant mieux la variabilité spatiale et temporelle des besoins en N. Ajuster la fertilisation azotée en cours de campagne semble donc indispensable pour tenir compte de la variabilité spatiale et temporelle des besoins en N, dans le but d'améliorer le NUE. Le fractionnement des apports et la prise en compte du statut azoté en cours de campagne semblent donc indispensables dans une démarche d'amélioration du NUE. Un meilleur NUE devrait également permettre de diminuer le risque de pollution par les nitrates d'origine agricole et le coût des apports (Quemada et al., 2019, Gabriel et al., 2017).

3.2.2. Ajustement de la dose bilan en cours de campagne (date, dose, spatialisation)

3.2.2.1. *Définition*

La dose bilan est le calcul d'une dose unique pour une parcelle, calculée en amont de la campagne. Dans le but d'avoir une meilleure intégration de la variabilité spatiale et temporelle des besoins en N, des outils d'aide à la décision (OAD) ont été développés. Ceux-ci proposent, en partant de la dose bilan, d'adapter à la hausse ou la baisse la dose apportée en cours de campagne. Ces OAD sont définis de la façon suivante par le ministère de l'agriculture, de l'agroalimentaire et de la forêt (2017) : « *l'ensemble des techniques permettant à une personne donnée d'opter pour la meilleure prise de décision possible* »

[...], soit l'ensemble des démarches d'aide au raisonnement des doses d'N et de leurs dates d'apport, en tenant compte d'une mesure du milieu ». Ainsi l'utilisation de ces OAD s'inscrit parmi les actions pouvant être mises en œuvre pour améliorer la gestion de l'N. La prise en compte de la variabilité spatiale et/ou temporelle des besoins en N devrait permettre d'ajuster les apports (dose et date) sans impact négatif à la récolte et de contribuer ainsi à une agriculture plus durable (Diacono et al., 2013 in Späti et al, 2021 ; Holland et Schepers, 2010 in Colaço et Bramley, 2018).

Les OAD sont caractérisés par le processus suivant : (i) une production de données par l'utilisation d'un modèle ou en se basant sur des mesures, (ii) une phase d'interprétation des données collectées à l'aide de règles de décision, (iii) l'implémentation des interprétations dans une solution appropriée au transfert des préconisations et (iv) le suivi des résultats dans un processus d'apprentissage continu (Patil et Shanwad, 2009 in Späti et al., 2021 et ministère de l'agriculture, de l'agroalimentaire et de la forêt, 2017).

Parmi les outils de pilotage utilisés par les agriculteurs, 2 catégories peuvent être distinguées en fonction de leurs stratégies : (i) les outils basés sur des mesures prises en cours de campagne et (ii) les modèles de bilan dynamiques qui se basent sur une mise à jour d'un ou plusieurs termes de la méthode du bilan.

(i) OAD basés sur des mesures en cours de campagne :

A partir de la dose bilan, les OAD basés sur des mesures proposent d'adapter le dernier apport, en quantité, en fonction de mesures du sol ou de la culture prises en cours de campagne. Ces mesures visent à estimer le statut azoté de la culture ou les ressources en N disponibles pour la croissance des cultures. Il peut s'agir de mesures faites par échantillonnage (destructives et ponctuelles) ou de mesures faites par capteurs. Différents capteurs sont utilisés : des capteurs manuels/portatifs (ex : N-sensor, Yara, Norvège), embarqués sur tracteurs (ex : N-tester, Yara, Norvège), embarqués sur drone (ex : N-tester, Yara, Norvège) ou sur satellites (ex : Farmstar, Terres Innovia/Arvalis/Airbus, France) (Späti et al., 2021). En fonction du mode d'échantillonnage et/ou des capteurs, la résolution et la précision des données seront variables (Späti et al., 2021). De plus, en fonction des capteurs utilisés, la quantité d'N conseillée peut être modulée à l'échelle de la parcelle, ou prendre en compte la variabilité spatiale des besoins en N au sein de la parcelle permettant une modulation intra parcellaire du dernier apport.

(ii) Modèle de bilan dynamique :

Les modèles de bilan dynamiques visent à optimiser la fertilisation azotée au contexte pédoclimatique, en se basant sur une simulation de la croissance de la culture et une mise à jour des variables d'entrée de la méthode du bilan (Meynard et al., 2002). Les simulations sont faites à un pas de temps journalier en prenant en compte les conditions météorologiques passées et en se basant sur un climat moyen pour la situation considérée. Différentes dynamiques d'N sont ainsi estimées, dans le sol, la plante et l'environnement (Apports d'N, minéralisation, lessivage, volatilisation, organisation microbienne des apports). Ces outils conseillent une date et une dose optimale d'apport à chaque étape du fractionnement (Meynard et al., 2002).

Parmi les OAD commercialisés en France, ce sont annuellement environ 600 000 ha pilotés à la pince N-tester, 50 000 ha par Wanaka (Paris, France), environ 40 000 ha par Agroconseil (Saint-Quentin, France) et 740 000 ha avec Farmstar (chiffres pour l'année 2015, ministère de l'Agriculture, de l'agroalimentaire et de la forêt, 2017). Les conseils issus de la télédétection se sont considérablement développés ces dernières années pour atteindre 1 million d'ha pilotés par télédétection en 2017. Le satellite est le moyen majoritairement utilisé (85% de la surface pilotée) et le marché est porté par l'utilisation de la télédétection pour le pilotage de la fertilisation (Lachia, 2020).

3.2.2.2. *Avantages et limites des OAD*

Les avantages à l'utilisation d'OAD mis en avant dans la littérature sont les suivants : une économie d'engrais de 5 à 45% sans impacts majeurs sur le rendement (Colaço et Bramley, 2018), entraînant un bénéfice d'en moyenne 25 €.ha⁻¹ (30 US \$.ha⁻¹) (Colaço et Bramley, 2018), une augmentation de la valorisation des apports pouvant aller jusqu'à 368% par rapport à des pratiques standard de fertilisation (Diacono et al., 2013 ; Li et al., 2009), une réduction du reliquat post récolte de 30 à 50% (Diacono et al., 2013). Pour les agriculteurs, ces outils permettent également un gain de temps et d'un point de vue réglementaire, ils lui permettent de justifier le déplafonnement de la dose définie par la méthode du bilan (Lachia, 2020).

Toutefois, les bénéfices générés par les OAD ne sont pas généralisables, ils sont dépendants du contexte dans lequel ils sont évalués : comme le niveau d'hétérogénéité de la parcelle dans le cas des bénéfices de la modulation parcellaire (Basso et al., 2015 ; Späti et al., 2021) ou le coût du service, de l'engrais et du prix de vente de la récolte dans le cadre du calcul du bénéfice économique (Colaço et Bramley, 2018 ; Späti et al., 2021). Pour un faible coût des engrais, les bénéfices de la modulation sont très faibles et ne couvrent pas les coûts liés à l'utilisation des technologies (Späti et al., 2021).

Späti et al. (2021) ont utilisé la modélisation pour illustrer l'impact des niveaux d'hétérogénéité (traduit par l'indice de Shannon) sur les bénéfices de différents outils (drone, satellite avec une résolution de 10 et 20m et échantillonnage pour une résolution de 50m). Leurs résultats soulignent que plus l'hétérogénéité des parcelles augmente, plus l'écart de bénéfice entre les OAD se creuse. Les technologies à haute résolution génèrent uniquement un bénéfice à partir d'un certain seuil d'hétérogénéité (Späti et al., 2021).

Concernant les bénéfices environnementaux, ils sont souvent basés sur des estimations car ils sont difficilement mesurables (Colaço et Bramley, 2018) et restent peu documentés (Meynard et al., 2002 ; ministère de l'Agriculture, de l'agroalimentaire et de la forêt, 2017). Enfin, plusieurs études mettent en évidence la nécessité de prendre en compte plus d'informations sur le sol (notamment le taux de minéralisation et l'N disponible) et les conditions météorologiques dans les conseils (Shanahan et al., 2008 ; Thompson et al., 2015 in Colaço et Bramley, 2018).

Problématique, objectifs et démarche de thèse

Améliorer la valorisation des apports d'engrais représente un enjeu majeur pour l'agriculture. Actuellement l'efficacité de l'utilisation de l'N (NUE) en céréales est en moyenne de 35%, une valeur relativement faible qui n'a pas augmenté ces dernières années (Omara et al., 2019). Cela signifie qu'en moyenne 65% des apports ne sont pas valorisés directement par la culture en place et peuvent donc être immobilisés ailleurs dans le cycle de cet élément essentiel, voire être source de pollutions azotées. Ainsi, à côté des perspectives offertes par la génétique et la modélisation fine des fournitures d'azote du sol, améliorer la valorisation des apports d'engrais représente un levier important pour réduire les pollutions azotées tout en maintenant un rendement élevé et une qualité satisfaisante à la récolte (Masclaux-Daubresse et al., 2010 ; Sharma et Bali, 2018). Selon Raun et al., 1999, Cassman et al., 2002 et Abebe et al., 2017 (in Sharma et Bali, 2017), le manque de synchronisation entre les apports et les besoins de la culture ainsi que la réalisation d'apports uniformes dans le temps et l'espace sont des pratiques agricoles à l'origine de ce faible NUE. Par conséquent, la connaissance du statut azoté de la culture en cours de croissance est un levier majeur permettant d'améliorer les pratiques de fertilisation et augmenter le NUE (Figure 13).

Dans ce contexte, le travail réalisé durant cette thèse porte sur **le suivi non-destructif de l'indice de nutrition azotée (INN) du blé tendre en cours de campagne, par proxi- et télédétection, dans le but d'intégrer par la suite ces connaissances dans une démarche de pilotage dynamique de la fertilisation azotée.**

Dans ce travail, le statut azoté de la culture sera donc suivi au moyen de mesures de l'INN. Le suivi de cet indice est d'autant plus intéressant qu'il est défini comme un indicateur à la fois spécifique (varie uniquement avec la nutrition azotée) et sensible (réactif aux changements de nutrition) au statut azoté (Lemaire et al., 2008). La mesure directe de l'INN, impliquant des prélèvements au champ et des mesures au laboratoire, étant destructive, chronophage et coûteuse, l'estimation indirecte de l'INN, par proxi- ou télé-détection a déjà été décrite dans la littérature comme prometteuse (Chen, 2015 ; Lemaire et al., 2019). C'est ce suivi non destructif par capteurs qui sera testé dans ce travail.

Les capteurs utilisés peuvent être des caméras ayant différentes résolutions spectrales (RGB, multispectrales, hyperspectrales, thermiques, etc.), des capteurs optiques foliaires, des spectrophotomètres, etc. (Padilla et al., 2018 ; Muñoz-Huerta et al., 2013). Ils peuvent être embarqués sur différents vecteurs (satellite, drone, tracteur, manuel, etc.) dont va dépendre la résolution spatiale des mesures. La télédétection regroupe les techniques de mesures réalisées à distance de la culture tandis que la proxidétection qualifie les mesures faites au contact de la végétation ou à quelques centimètres, que ce soit avec des capteurs venant pincer la feuille ou des appareils de mesure à faible distance au-dessus du couvert. Ces capteurs permettent une estimation indirecte du statut azoté, en se basant sur des mesures de variations de transmittance, de fluorescence et de réflectance du couvert qui permettent d'évaluer la teneur en chlorophylles des feuilles, elles-mêmes fortement liées au contenu en N (Haboudane et al., 2002 ; Ercoli et al., 1993 in Baret et Fourty, 1997 ; Shepers et al., 1996 in Padilla et al., 2014, cf. 2.).

Dès lors, des indices de végétations (IV), dont le principe est de combiner les mesures de réflectance dans différentes longueurs d'onde, ont été développés et sont reconnus comme des indicateurs fiables du développement de la culture et de son statut azoté (Gabriel et al., 2017). Plusieurs études se sont intéressées à développer de nouvelles formulations d'indices ou à intégrer de nouvelles longueurs d'onde en vue d'améliorer la sensibilité et la spécificité au changement de statut azoté du couvert tout

en diminuant la variabilité due aux autres facteurs par rapport à l'étude individuelle des longueurs d'onde (Basso et al., 2015 ; Argento et al., 2020 ; Zhang et al., 2018 ; Li et al., 2014). Toutefois, plusieurs études mettent en évidence la difficulté d'avoir un IV unifié, capable de prédire le statut azoté dans une large gamme de situations (Li et al., 2014 ; Chen, 2015).

Sur base du contexte général décrit précédemment et ci-dessus, un premier volet du présent travail portera sur la mise en place d'une méthode d'évaluation non destructive du statut azoté du blé tendre. Cette méthode sera basée sur la conception de modèles paramétriques et non-paramétriques, construits à partir de mesures de réflectance de la culture faites par télédétection en cours de campagne et complétées par des mesures prises en proxidtection par transmittance et fluorescence. La figure 14 présente le plan détaillé du travail à suivre, avec les chapitres 1 à 3 visant à la mise en place de la méthode d'évaluation non destructive du statut azoté. Ces chapitres traiteront les données obtenues à partir de mesures réalisées sur 3 essais présentant un gradient de fertilisation azotée. Le chapitre 4 complète ces résultats par une analyse de la valorisation des apports et de la mise en place des composantes de rendement du blé tendre. Ces deux éléments sont pertinents à considérer dans une démarche de pilotage de la fertilisation afin d'identifier les stades clefs à piloter. Un second volet de cette thèse portera sur le suivi des performances agronomiques et environnementales de différents Outils d'Aide à la Décision (OAD) proposés actuellement aux agriculteurs pour piloter la fertilisation. Le chapitre 5 présente les résultats de l'évaluation de quatre de ces méthodes, sur 2 sites expérimentaux, à l'échelle de la succession culturale (orge-blé-colza-blé), de 2017 à 2020.

Toutes ces informations seront discutées à la fin de ce travail dans le but de synthétiser les grands enseignements à retenir de ces 3 années d'expérimentation, mais aussi projeter les perspectives ouvertes par ce travail.

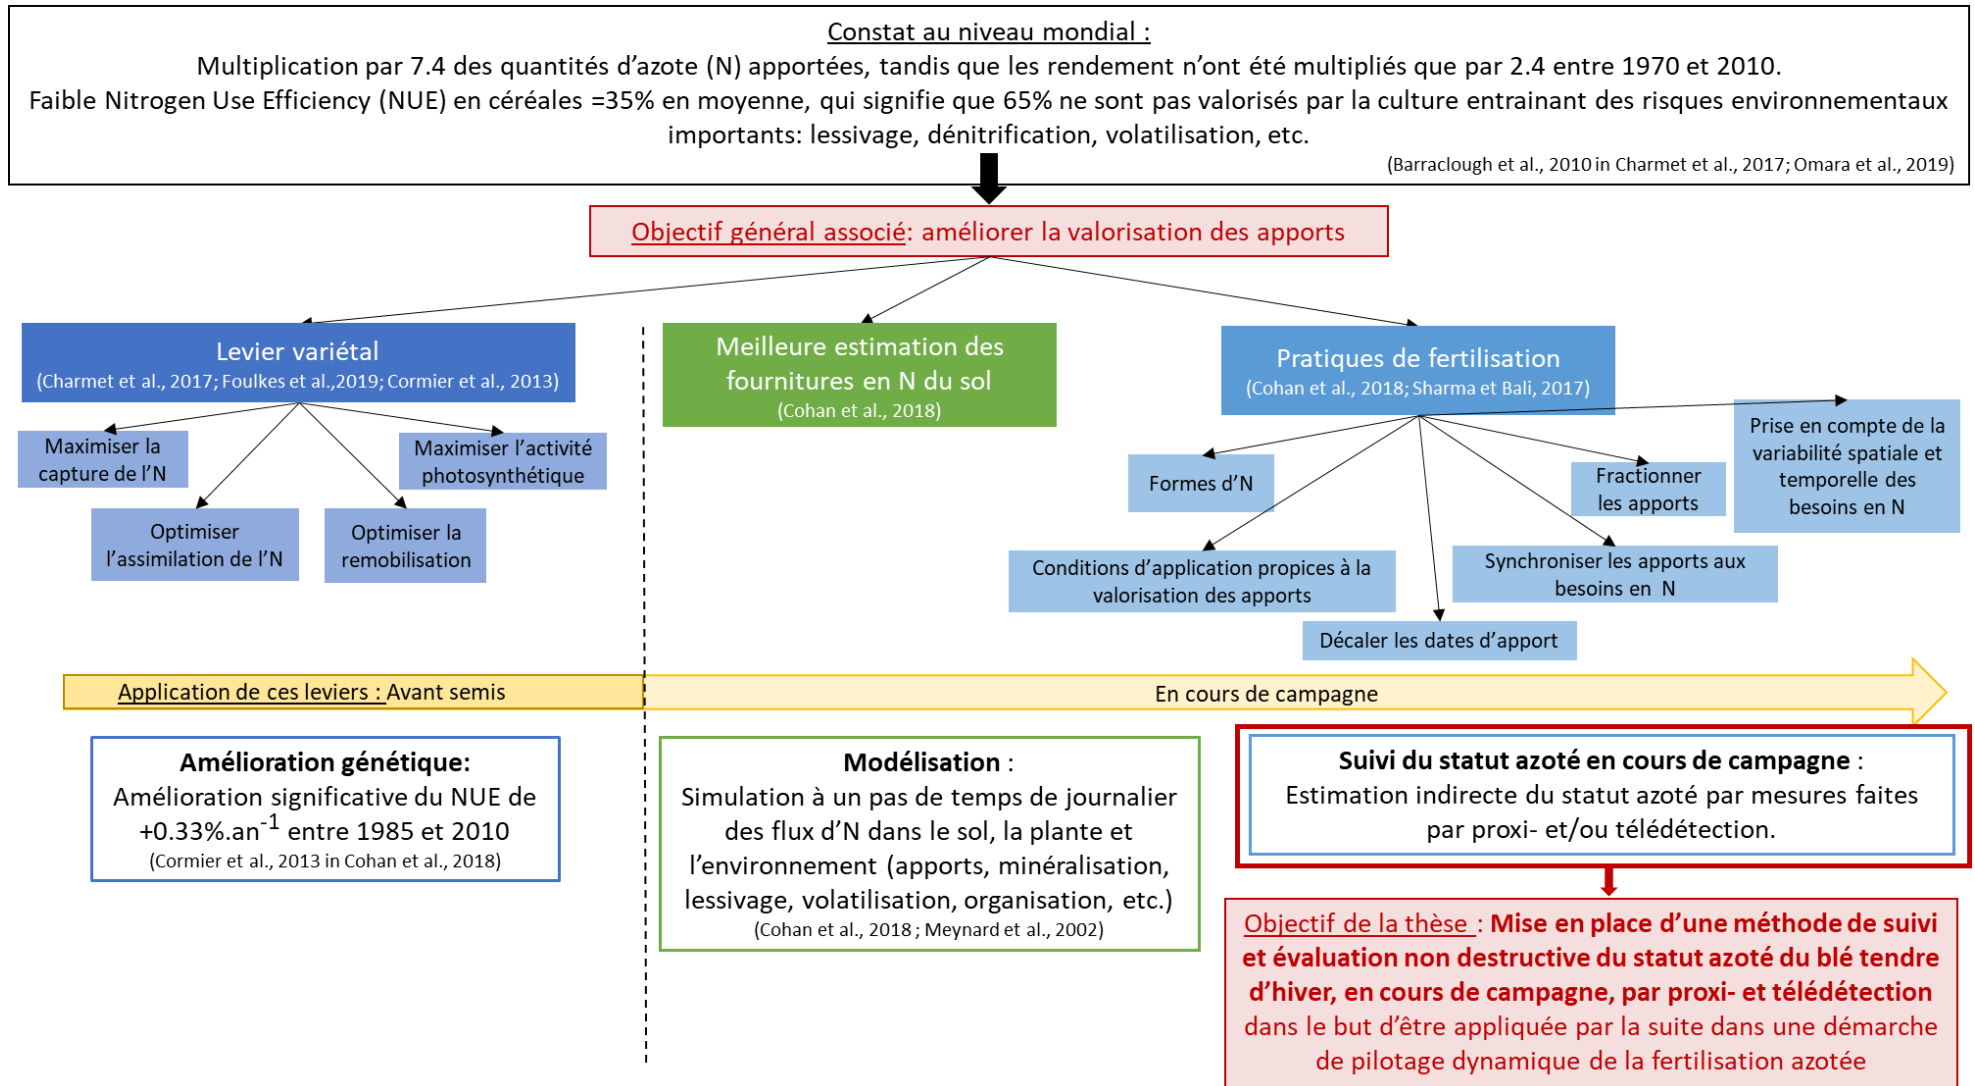


Figure 13 : Schéma représentant le contexte général de la thèse et comment l'objectif de la thèse s'inscrit parmi les leviers visant à améliorer la valorisation des apports




Figure 14 : Schéma de l'organisation des chapitres du manuscrit en fonction des objectifs suivis par année d'étude

Résultats

Chapitre I

Évaluation des performances d'indices de végétation calculés à partir d'images prises par drone et exploration de nouvelles combinaisons de longueurs d'onde pour suivre l'état de nutrition azotée du blé tendre d'hiver

Améliorer la valorisation des apports d’engrais, représente un enjeu majeur pour réduire les pollutions azotées tout en maintenant un rendement élevé et une qualité satisfaisante à la récolte. Une meilleure prise en compte de la variabilité spatiale et temporelle des besoins en azote (N) de la culture permettrait d’adapter les apports dans le temps et dans l’espace et ainsi d’améliorer leur valorisation. La connaissance du statut azoté de la culture en cours de croissance devrait donc permettre de connaître ses besoins afin d’améliorer les pratiques de fertilisation. Tout au long de ce travail, l’indice de nutrition azoté (INN) a été étudié comme indicateur du statut azoté du blé (Justes et al. 1994). Celui-ci est particulièrement intéressant puisqu’il est spécifique et sensible aux changements de nutrition azotée (Lemaire et al., 2008). En tenant compte à la fois de la biomasse et de la concentration en N, il peut être comparé à une référence afin d’identifier une éventuelle carence azotée du couvert végétal (Justes et al., 1994 ; Chen, 2015 ; Lemaire, 2019).

Dans ce contexte, les estimations indirectes du statut azoté par proxi- ou télédétection présentent un intérêt particulier pour estimer de façon non destructive le statut azoté en se basant sur des mesures de variations de transmittance, fluorescence et réflectance du couvert, permettant d’évaluer la teneur en chlorophylles des feuilles, elles-mêmes fortement liées au contenu en N (Haboudane et al., 2002 ; Ercoli et al., 1993 in Baret et Fourty, 1997 ; Shepers et al., 1996 in Padilla et al., 2014 ; Lemaire, 2019. Zheng et al., 2018). Il est avéré que les indices de végétation (IV), calculés en combinant le rayonnement réfléchi par le couvert dans différentes longueurs d’onde, sont des indicateurs fiables du développement de la culture et de son statut azoté (Gabriel et al., 2017). Ainsi, de nombreuses études ont cherché à développer de nouvelles formulations d’indices ou à intégrer de nouvelles longueurs d’onde en vue d’améliorer la sensibilité et la spécificité des IV aux variations de statut azoté (Basso et al., 2015 ; Argento et al., 2020 ; Zheng et al., 2018 ; Li et al., 2014). Toutefois, plusieurs études mettent en évidence la difficulté d’avoir un IV unifié, capable de prédire le statut azoté dans une large gamme de situations (Li et al., 2014 ; Chen, 2015, Berger et al., 2020).

Ce premier chapitre propose tout d’abord d’évaluer les performances de 14 IV ou combinaisons d’IV pour suivre l’INN du blé. Ces IV ont été calculés à partir de mesures de réflectance du couvert prises dans quatre longueurs d’onde (Sequoia camera, Parrot, Paris, France), en 2019. Dans un second temps, l’acquisition d’une caméra multispectrale modulable (Kernel, Mapir, San Diego, USA) a permis, dès 2020, l’étude de nouvelles longueurs d’onde, de 405 à 940nm, dans le but d’en identifier de plus sensibles aux changements de statut azoté. Enfin, en parallèle des mesures effectuées par télédétection, des mesures par proxidtection ont été réalisées avec un capteur optique foliaire (Dualix, Force A, Orsay) afin d’évaluer la pertinence de cet outil pour suivre le statut azoté du blé en cours de campagne. Les résultats présentés dans ce chapitre se basent sur des mesures prises en 2019 et 2020 sur deux sites expérimentaux présentant un gradient de fertilisation azotée, à Houvin-Houvigneul (62) et Savy-Berlette (62).

Ce travail a fait l’objet d’une communication orale lors de la 13ème conférence européenne de l’agriculture de précision (ECPA) à Budapest en juillet 2021.

Bouchard M.A., Andriamandrosa A.L.H., Andrianarisoa S., Waterlot C., Siah A., Guille C., Vandoorne B. 2021. Evaluating UAV-based vegetation indices and exploration of new wavelengths combination to monitor winter wheat crop nitrogen status. In: J.V. Stafford (Ed.) Precision Agriculture '21: Proceedings of the 13th European Conference on Precision Agriculture, Wageningen, The Netherlands: Wageningen Academic Publishers. pp. 469-476. doi.org/10.3920/978-90-8686-916-9_56.

Evaluating UAV-based vegetation indices performance and exploration of new wavelengths combination to monitor winter wheat crop's nitrogen status

Bouchard M-A.¹, Andriamandroso A.L.H.¹, Andrianarisoa S.¹, Waterlot C.², Siah A.¹, Guille C.³, Vandoorne B.¹

¹ *Université de Liège, Junia, UMRT 1158 BioEcoAgro - Conduction, optimization and design of cropping systems meeting multi-criteria objectives, B-5030 Gembloux, Belgique*

² *Univ. Lille, Institut Mines-Télécom, Univ. Artois, Junia, ULR 4515 – LGCgE, Laboratoire de Génie Civil et géo-Environnement, F-59000 Lille, France*

³ *Chambre régionale d'agriculture du Nord-Pas-de-Calais, Saint Pol sur Ternoise, France*
marie-astrid.bouchard@junia.com

Abstract

A dynamic fertilization method based on unmanned aerial vehicle (UAV) imagery to estimate crop nitrogen (N) status appears to offer good opportunities to improve N use efficiency. The objectives of this study are to evaluate UAV-based vegetation indices to monitor N status, and to test new wavelengths to improve the measurement and prediction of the nitrogen nutrition index (NNI). Two fields showing various patterns of NNI dynamics were monitored in the North of France. During the first growing season (2019), 14 commonly-used vegetation indices (VI) were compared. During the second year (2020), to improve the accuracy in detecting the crop N response, the wheat canopy reflectance at 17 different wavelengths (405nm to 945nm) was measured. At all stages, reflectance at three wavelengths was identified as best correlated to NNI (632nm, 615nm, 590nm), and 780nm may present a relevant application. Future developments will tend to improve the accuracy of NNI estimation model.

Keywords: Nitrogen Nutrition Index, nitrogen fertilization, unmanned aerial vehicle, vegetation index, winter wheat.

Introduction

Assessing crop nitrogen (N) status in real time is important for adapting the N fertilizer rate in fertilization precision management. N status is calculated as a function of biomass and leaf N concentration (Niu et al., 2019). To provide dynamic monitoring of crop N status, predicting the nitrogen nutrition index (NNI) is a good indicator (Chen et al., 2013) and Ravier et al. (2017) showed that estimating NNI is interesting in order to manage fertilization. Indeed, from such method it would be possible for farmer to apply fertilization regarding to crop demand in real time. A fertilization method based on monitoring of crop N status during crop growth allows for a better adaptation to the annual requirement and reduces the risk of nitrate leaching (Goffart et al., 2013). Because most of N in the leaf is correlated to leaf chlorophyll content, assessing NNI by remote sensing offers good opportunities: it is a rapid, non-destructive and an accurate method (Niu et al., 2019). The use of a multispectral camera mounted on an unmanned aerial vehicle (UAV) allows measurement of canopy reflectance at different wavelengths and the subsequent calculation of various vegetation indices (VI) correlated to crop N status. However, few studies have been carried out to correlate NNI directly with VI with the aim of developing a method to assess NNI during crops growth. Most studies focus on the correlation between VI and crop leaf chlorophyll concentration, which gives an indirect assessment of N status (Haboudane et al., 2008). Furthermore, Li et al (2014) highlighted that the relationship between VI and the crop N content are often inconsistent.

The objectives were (i) to evaluate the use of different known VI calculated from UAV imagery to monitor N status; and (ii) to test new wavelengths to improve the correlation and prediction of NNI. In addition, non-destructive crop N status measurements were made with an optical sensor in order to assess its accuracy in monitoring NNI in this context.

Materials and methods

Experimental sites and fertilization rates

The study was carried out on winter wheat in the north of France (Pas-de-Calais region, 62) during two growing seasons (2018-2019 and 2019-2020). Two wheat crop experiments showing various patterns of NNI dynamics were monitored, representing 13 different combinations of total N fertilizer levels and splitting strategies with four repetitions (blocks) (Tables 1 and 2). Each trial has represented 1170m² in 2019 and 2145m² in 2020, implemented in an homogeneous area of a field of 7.9ha in 2019 and 11.2ha in 2020. N applications were made with 27% ammonium nitrate. For the 2019 experiment, winter wheat was sown on October 17th (2018) with Costello variety (KWS Momont, 2015, France). For the 2020 season, the Chevignon variety (Saaten Union, 2017, France) was sown on October 24th, 2019. At harvest, yield ranged from 79.4 q/ha (Control) to 126.8 q/ha (R+40) in 2019 and from 51.7 q/ha (Control) to 95.8 q/ha (2020_2) in 2020. Analysis of variance (ANOVA) with Tukey's multiple comparison procedure was performed to evaluate the influence of fertilization at harvest. A p-value of 0.05 was applied to differentiate the means of the N treatments and fertilization had a significant effect for the 2 years of study.

Table 1. Site location, soil mineral N content at 90cm measured at the end of winter, fertilizer rates and the reference dose

Site	Location, degrees	Soil mineral N content at 90cm (kg N.ha ⁻¹)	Fertilization gradient (kg N.ha ⁻¹)	Reference dose (R)* (kg N.ha ⁻¹)
Houvin-Houvigneul	50.308324, 2.385824	72	0 – 290	210
Savy-Berlette	50.343387, 2.550636	91	0 – 315	180

*calculated according to the balance sheet method (Comifer, 2013)

 Table 2. Fertilization strategies in 2019: N fertilizer rates in kg N.ha⁻¹, reported per Zadoks growth scale in 2019 (a) and 2020 (b)

(a) Input	Z29	Z31	Z32	Z39	Z51	(b) Input	Z29	Z31	Z32	Z39
Control	0	0	0	0	0	Control	0	0	0	0
R-80	40	50		40		R-80	20	60		20
R-40	40	90		40		R-40	40	60		40
(R)	40	130		40		(R)	40	100		40
R+40	40	110	40	60		R+40	40	100	40	40
R+80	60	130	40	60		R+80	60	100	40	60
2019_1	40	130				2020_1	60	60		60
2019_2	40	130		80		2020_2	80	40		60
2019_3	80	90		120		2020_3	30	30		30
2019_4		150		60		2020_4	105	105		105
2019_5		150		40	20	2020_5	80	100		
2019_6	40	90	40	40		2020_6		80	40	60
2019_7	40	130		40		2020_7	40	100		40

Measurements were taken at 4 Zadoks growth stages: Z30 (beginning stem elongation), Z32 (second node detectable), Z39 (flag leaf ligule just visible) and Z60 (beginning flowering) (Zadoks et al., 1974).

Crop analysis and ground level measurements

To find a correlation between crop N status and remote sensing measurements of reflectance, the N content was measured on the aerial part chemically. Biomass samples were collected in a row of 50 cm in each plot and dried at 65°C. After the sample had been finely ground, the N content was measured on the aerial part chemically (Dumas method, NF EN ISO 16634-1). NNI is calculated using Eq. (1) as the ratio of measured N concentration (%N) and the critical N concentration (%N_c) for a defined dry biomass (DM). For winter wheat, N_c is obtained using Eq. (2) (Justes et al., 1994).

$$NNI = \frac{\%N}{\%N_c} \quad (1)$$

$$\text{for } DM < 1.55 \text{ T/ha } N_c = 4.4, \text{ for } DM > 1.5 \text{ T/ha } N_c = 5.35DM^{-0.442} \quad (2)$$

In addition, at each sampling date, non-destructive measurements of the crop N status were taken using a Dualex Scientific sensor (Force A, Orsay, France). The Dualex estimates the chlorophyll and polyphenolics content based on transmittance and absorbance measurement in

UV and visible lights. Measurements were always done with the adaxial leaf side facing the light sources. Using this tool, a nitrogen balance index (NBI) ratio is calculated - i.e. the ratio between chlorophyll and flavonols content - as an indicator of crop N status. For each microplot, the mean NBI was obtained from the average of 12 individual leaf measurements.

UAV image acquisition and processing

UAV flights were made as close as possible to ground level to obtain measurements at 30m height in favorable conditions. In 2019, the UAV images were acquired with a multispectral Sequoia Camera (Parrot, Paris, France) mounted on Phantom UAV (DJI, Shenzhen, China). The light reflected was measured in Green 550nm (± 40 nm), Red 660nm (± 40 nm), Red Edge 735nm (± 10 nm) and in Near InfraRed (NIR) 790nm (± 40 nm).

In 2020, to enhance the investigation of the relationship between VI and NNI, a UAV (M1Agri, ADT drones, Soissons, France) equipped with a six lens multispectral modular camera (Kernel camera, Mapir, San Diego, CA, USA) was used. The modular camera used enabled us to change the filters among 17 wavelengths: 405nm (± 50 nm), 450nm (± 50 nm), 490nm (± 75 nm), 518nm (± 50 nm), 550nm (± 50 nm), 590nm (± 50 nm), 615nm (± 75 nm), 632nm (± 50 nm), 650nm (± 50 nm), 685nm (± 50 nm), 725nm (± 50 nm), 780nm (± 50 nm), 808nm (± 50 nm), 850nm (± 100 nm), 880nm (± 50 nm), 905nm (± 50 nm), 940nm (± 200 nm). Using the six lenses, three flights per stage are required to obtain images in 17 wavelengths.

Data analysis

In a first time ANOVA considering two fixed factor (growth stage and N fertilization rates) and one random factor (block) was used to report the effect of N rates and growth stage on NNI. Then ANOVA were made stage by stage.

In 2019, 14 commonly used VI were calculated on QGIS (QGIS Development Team 2021, version 3.10) after generating the orthoimages on Pix4D (Pix4D, Lausanne, Switzerland) (Table 3). In 2020, image processing and calibration were made on Mapir software, using target calibration picture. Orthoimages were generated on Pix4D and normalization was made on QGIS. The data were exported from QGIS per microplot and analyzed in Rstudio (RStudio Team 2019, version 3.6.2). Correlation analysis was conducted to obtain the relationship between NNI and NBI, and between NNI and the 14 VI. The 14 indices were chosen as having varying levels of complexity and using different wavelengths. In 2020, to explore the correlation and prediction of NNI, the data set was divided per stage: 75% of the data were randomly selected as the modeling data set, while the remaining 25% were used for validation. Different modeling methods were tested to predict NNI. In order to set aside wavelengths with little interest and identify wavelengths of interest, linear regression between NNI and individual wavelengths were made. A multiple linear regression with the six most responsive wavelengths was then performed with the aim of increase the NNI prediction. The number of wavelengths was fixed at six, which corresponds to the number of MAPIR camera lenses. The coefficient of determination (R^2) was chosen as the indicator to evaluate the accuracy of the model prediction.

Table 3. Studied VI and formulations

Input	Index	Equation
SR	Simple Ratio	NIR/Red
GRVI	Green Ratio Vegetation Index	$NIR/Green$
NDVI	Normalized Difference Vegetation Index	$(NIR-Red)/(NIR+Red)$
GDNVI	Green Normalized Difference Vegetation Index	$(NIR-Green)/(NIR+Green)$
RDVI	Reformed Difference Vegetation Index	$(NIR-Red)/\sqrt{(NIR + Red)}$
OSAVI	Optimized Soil Adjusted Vegetation Index	$(NIR-Red)/(NIR+Red+0.16)$
TDVI	Transformed Difference Vegetation Index	$1.5 \times [(NIR-Red)/\sqrt{(NIR^2 + Red + 0.5)}]$
MSAVI2	Modified Soil Adjusted Vegetation Index 2	$(2 \times NIR + 1 - \sqrt{((2 \times NIR + 1)^2 - 8 \times (NIR - Red))})/2$
NDRE	Normalized Difference Red Edge	$(NIR - RedEdge)/(NIR + RedEdge)$
MCARI	Modified Chlorophyll Absorption in Reflectance Index	$((NIR-Red)-0.2(NIR-Green)) \times (NIR/Green)$
TCARI	Transformed Chlorophyll Absorption in Reflectance Index	$3 \times [(RedE-Red)-0.2 \times (RedE-Green)] \times (RedE/Red)$
NDRE/NDVI		
TCARI/OSAVI		
MCARI/OSAVI		

Results and discussion

For the two years studied, NNI was affected by N fertilizer rates, for all growths stage in 2019 (Z30 : $p_v=3e-04$, Z32 : $p_v<0,0001$, Z39: 0,0035) and since stage Z32 in 2020 (Z30: $p_v=0,3007$ and Z32, Z39, Z60 : $p_v<0,0001$).

Correlation between NBI and NNI

The correlations between NBI and NNI were studied for stages Z30, Z32, Z39 in 2019 and for stages Z32 and Z60 in 2020. All stages included, correlation remained low ($R^2=0.16$ in 2019), but stage by stage, the correlation coefficient ranges from 0.32 (Z39-2019) to 0.74 (Z32-2020) (Figure 1). The good relationship between NBI and NNI was confirmed during the two-year study, especially for measurements taken at stage Z32. For this stage, the relationship between NBI and NNI was high ($R^2= 0.69$ in 2019 and 0.74 in 2020). Regression was similar for the two years studied ($y=-0.11+0.031x$ in 2019 and $y=-0.14+0.029x$ in 2020). These results show a relevant application of Dualex to estimate crop N status easily and non-destructively. It is consistent with the study carried out by Quemada et al. (2019) which highlighted the potential of Dualex measurement to adjust N fertilization in early stages. In addition, these results show that it would be interesting to enlarge the application of this study to a large scale.




Figure 1 : Linear relationship between NNI and NBI for Z30 and Z39 in 2019 and Z60 in 2020 (a) and for Z32 in 2019 and 2020 (b)

Correlation between VI and NNI

In 2019, the correlation between VI and NNI was studied at stages Z30 and Z39 (Table 4).

Table 4. Determination coefficient (R^2) for linear regressions between NNI and different VI at stages Z30 and Z39

VI	SR	GRVI	NDVI	GNDVI	RDVI	OSAVI	TDVI
R^2 at Z30	0.54	0.58	0.42	0.51	0.52	0.54	0.52
R^2 at Z39	0.47	0.37	0.46	0.40	0.45	0.45	0.42
VI	MSAVI2	NDRE	MCARI	TCARI	NDRE/ NDVI	TCARI/ OSAVI	MCARI/ OSAVI
R^2 at Z30	0.47	0.57	0.57	0.51	0.54	0.52	0.58
R^2 at Z39	0.42	0.44	0.37	0.45	0.42	0.45	0.36

As identified by other studies, VI perform better at the beginning of the cycle than at the end of the cycle (Erdle et al., 2011, Zheng et al., 2018). At every stage, R^2 between VI and NNI have remained moderate and there were few differences between the indices (R^2 from 0.42 for NDVI to 0.58 for GRVI and MCARI/OSAVI at Z30 and from 0.36 for MCARI/OSAVI to 0.47 for SR at Z39). Making VI more complex by incorporating more bands or combining different indices did not generate higher accuracy. According to these results, it is difficult to select a discriminant VI among commonly used VI. As mentioned by Chen (2015), NNI prediction by existing methods is highly variable.

Exploration of the relationship between different wavelengths and NNI

In 2020, the reflectance at different wavelengths taken independently are better correlated with the NNI at the end of the cycle than at the first stage. In fact, R^2 ranged from 0.0029 (for 940nm) to 0.28 (for 780nm) at Z30, however, correlations were much better at Z39 and Z60 with R^2 reaching 0.48 (for 685nm at Z39) and 0.47 (for 725nm at Z60) (Table 5). For each stage, among the six best-correlated wavelengths, three were common to the studied stages: 632nm, 615nm, 590nm. These wavelengths are not widely used in VI to monitor N status. The indices containing NIR and/or RedEdge appear to be the most efficient in several studies (Jinru & Su, 2017, Zheng et al., 2018, Fu et al., 2020). Plant reflectance is higher in that range of the spectrum (Hansen & Schjoerring, 2003, Adao et al., 2017) due to chlorophyll a and b plant content. According to the study by Hansen & Schjoerring (2003), plant reflects a lot from 700nm and reflected well but less so between 500 and 600nm. A hypothesis would be that in this study, the slight reflectance peak between 500 and 600nm was more sensitive to different fertilizations levels. For two stages, especially for Z30, light reflected at 780nm at the interface between NIR and RedEdge, was well correlated to NNI. This result, consistent with the wavelength used in VI's, highlighted the potential of the light reflected in 780nm to predict NNI and supported the use of NIR in VI's.

Table 5. R^2 for simple linear regressions between NNI and the light reflected among the six best-correlated wavelengths

Wavelength Z30 (R^2)	Wavelength Z39 (R^2)	Wavelength Z60 (R^2)
780nm (0.28)	685nm (0.48)	725nm (0.47)
550nm (0.19)	650nm (0.44)	590nm (0.38)
632nm (0.19)	615nm (0.43)	615nm (0.36)
590nm (0.18)	632nm (0.38)	650nm (0.29)
615nm (0.18)	518nm (0.37)	632nm (0.25)
685nm (0.14)	590nm (0.36)	780nm (0.13)

In order to improve NNI prediction, multiple linear regression was made with the six most correlated wavelengths (Table 6). For each stage, 25% of the data set was used to validate the model prediction (R^2 validation in Table 6). Using a model with these six wavelengths further increases the predictive capacity of the NNI ($R^2=0.49$ at Z30, $R^2=0.55$ at Z39 and 0.58 at Z60) compared to individual wavelengths. As with linear models, multiple regressions are more efficient in predicting NNI at the end of the cycle.

Regarding R^2 validation and comparing 2019 and 2020 results, multiple regressions with new wavelengths did not significantly improve NNI prediction over VI. However, 2020 results on exploration of new wavelengths offered interesting outcomes. Firstly the addition of NBI in the regression relationship between NNI and wavelengths seems to increase model prediction greatly. For example, for Z60 R^2 increased from 0.61 to 0.75 which is the best R^2 obtained. Thus mixing information from UAV imagery and the NBI easily measured by the Dualex performed well. This highlights the role of the Dualex in allowing an improvement of NNI prediction with NBI values in a NNI monitoring approach by UAV-based method. Secondly, NNI and reflectance in different wavelengths will be of further use in other models. For example, partial least square regression (PLSR), which overcomes the problems of the correlation between reflectance wavelengths.

Table 6. R² and AIC (Akaike’s Information Criterion) obtained for multiple linear regression made with the six most correlated wavelengths and NNI at stages Z30, Z39 and Z60. R² validation was obtained for model validation.

Stage	AIC	R ²	R ² Validation
Z30	-142.15	0.38	0.49
Z39	-108.07	0.61	0.55
Z60	-131.09	0.61	0.58

Conclusions

Good correlation between NNI and NBI was observed for different stages during the 2-year study (R² until 0.74). Even if destructive methods to estimate the N content are considered very accurate, they are time-consuming, expensive and difficult to spatialize. The measurement of the NBI indicator seems to be a relevant application as an easy and non-destructive way to estimate crop N status. Moreover, its use could be extended to test the prediction of models based on drone imagery on a larger scale in a fast and efficient way.

Secondly, the study showed encouraging results regarding the use of UAV imagery to assess crops N status. Among 14 commonly-used VI the accuracy was acceptable to estimate NNI and the exploration of new wavelengths showed encouraging results. Contrary to VI which perform better at the beginning of the cycle, The reflectance in the different wavelengths, taken independently, improved NNI prediction at the end of the cycle. At each stage, three wavelengths were identified as well-correlated to NNI (632nm, 615nm, 590nm) and 780nm may present a relevant application. Further analysis is necessary to improve the accuracy of NNI estimation model by testing PLSR.

Finally, combining UAV imagery and proximal sensing with NBI measurement seems to improve NNI prediction. Using UAV imagery to estimate NNI allows spatialized data to be obtained, while according to the results, the addition of the NBI will provide better NNI prediction.

Acknowledgements

This project was funded by Agence de l’Eau Artois Picardie and Junia.

References

- Adao T., Hruska J., Padua L., Bessa J., Peres E., Morais R., Sousa J.J. 2017. Hyperspectral Imaging: A Review on UAV-Based Sensors, Data Processing and Applications for Agriculture and Forestry. *Remote sensing* **9**(11) 1110-1140.
- Chen, P., Wang, J., Huang, W., Tremblay, N., Ou, Y., Zhang, Q. 2013. Critical Nitrogen Curve and Remote Detection of Nitrogen Nutrition Index for Corn in the Northwestern Plain of Shandong Province, China. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* **6**(2) 682-689.
- Chen P. 2015. A Comparison of Two Approaches for Estimating the Wheat Nitrogen Nutrition Index Using Remote Sensing. *Remote sensing* **7** 4527-4548.
- COMIFER. 2013. Calcul de la fertilisation azotée (Calculation of nitrogen fertilization). https://comifer.asso.fr/images/publications/brochures/BROCHURE_AZO_TE_20130705web.pdf (last accessed 10/12/20)
- Erdle K., Mistele B., Schmidhalter U. 2011. Comparison of active and passive spectral sensors in discriminating biomass parameters and nitrogen status in wheat cultivars. *Field Crops Research* **124** 74-84.
- Fu Z., Jiang J., Gao Y., Krienke B., Wang M., Zhong K., et al. 2020. Wheat Growth Monitoring and Yield Estimation based on Multi-Rotor Unmanned Aerial Vehicle. *Remote Sensing* **12** 508-527.
- Goffart, J. P., Abras, M., Ben Abdallah, F. 2013. Gestion de la fertilisation azotée des cultures de plein champ. Perspectives d'amélioration de l'efficacité d'utilisation de l'azote sur base du suivi du statut azoté de la biomasse aérienne (Nitrogen fertilization management of open-field crops. Opportunities for improvement of nitrogen use efficiency based on crop nitrogen status monitoring). *Biotechnology, Agronomy, Society and Environment* **17**(S1) 221-230.
- Haboudane D., Tremblay N., Miller J.R. 2008. Remote Estimation of Crop Chlorophyll Content Using Spectral Indices Derived From Hyperspectral Data. *IEEE Transactions on Geoscience and Remote Sensing* **46**(2) 423-437.
- Hansen P.M., Schjoerring J.K. 2003. Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. *Remote Sensing of Environment* **86** 542-553.
- Jinru X. and Su B. 2017. Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. *Journal of Sensors* **2017**(1) 1-17.
- Justes, E., Mary, B., Meynard J-M., Machet J-M., Huché-Thélier L. 1994. Determination of a Critical Nitrogen Dilution Curve for Winter Wheat Crops. *Annals of Botany* **74** 397-407.
- Li F., Mistele B., Hu Y., Chen X., Schmidhalter U. 2014. Reflectance estimation of canopy nitrogen content in winter wheat using optimised hyperspectral spectral indices and partial least squares regression. *European Journal of Agronomy* **52** 198-209.
- Niu, Q., Feng, H., Li, C., Yang, G., Fu, Y., Li, Z., et al. 2019. Estimation of leaf nitrogen concentration of winter wheat using uav-based RGB imagery. *IFIP Advances in Information and Communication Technology* **546** 139-153.
- QGIS Development Team. 2021. QGIS Geographic Information System. Open Source Geospatial Foundation Project. <http://qgis.osgeo.org> (last accessed 04/02/21)
- Quemada M., Pancorbo J.L., Alonso-Ayuso M., Gabriel J.L., Lopez-Herrera J, Perez-Martin E. 2019. Vegetation indices from remote sensing imagery as proxies for yield and grain N in wheat. In: J.V. Stafford (Ed.) *Precision Agriculture '19: Proceedings of the 12th European Conference on Precision Agriculture, Wageningen, The Netherlands*:

- Wageningen Academic Publishers. pp. 323-330.
- Ravier C., Quemada M., Jeuffroy M.H. 2017. Use of a chlorophyll meter to assess nitrogen nutrition index during the growth cycle in winter wheat. *Field Crops Research* **214** 73-82.
- RStudio Team. 2019. RStudio: Integrated Development for R. RStudio, PBC, Boston, MA. <http://www.rstudio.com/> (last accessed 04/02/2021)
- Zadoks J.C., Chang T.T., Konzak C.F. 1974. A decimal code for the growth stages of cereals. *Weed Research* **14** 415-421.
- Zheng H., Li W., Jiang J., Liu Y., Cheng T., Tian Y., et al. 2018. A Comparative Assessment of Different Modeling Algorithms for Estimating Leaf Nitrogen Content in Winter Wheat Using Multispectral Images from an Unmanned Aerial Vehicle. *Remote Sensing* **10** 2026-2042.

Chapitre II

Analyse comparative de modèles paramétriques et non paramétriques pour évaluer et suivre l'indice de nutrition azotée (INN) du blé d'hiver en cours de croissance à l'aide d'images multispectrales obtenues par drone

De nombreuses études ont cherché à développer de nouvelles formulations d'indices de végétation (IV) ou à intégrer de nouvelles longueurs d'onde en vue d'améliorer leurs sensibilité et spécificité aux variations de statut azoté (Basso et al., 2015 ; Argento et al., 2020 ; Zheng et al., 2018 ; Li et al., 2014). Des longueurs d'onde plus sensibles au statut azoté ont été identifiées principalement dans le rouge, le NIR (proche infrarouge) et le RedEdge, tandis que des formulations ont été créées de façon à être moins affectées par l'environnement (réflectance du sol, sensibilité à l'environnement, etc.).

Malgré cela, les IV présentent toujours certaines limites et il est difficile de construire un IV unifié capable de prédire le statut azoté dans un grand nombre de situations, à différents stades de croissance et pour plusieurs variétés (Li et al., 2014). Cela a également été mis en évidence dans le **premier chapitre** où les IV traditionnellement utilisés présentaient tous une corrélation moyenne au statut azoté et où il était difficile d'en identifier un qui soit plus discriminant pour ce dernier. Ces résultats ont justifié l'intérêt d'explorer de nouvelles longueurs d'onde. Ainsi, la caméra Kernel (Mapir, San Diego, CA, USA), utilisée dès 2020, a permis cette investigation grâce à la prise de mesures de réflectance du couvert dans 15 longueurs d'onde. Dans un premier temps, les longueurs d'onde ont été étudiées individuellement par régressions linéaires simples. Des régressions linéaires multiples ont ensuite été réalisées avec les longueurs d'onde les plus liées au statut azoté individuellement (**chapitre 1**). Cependant, les IV par leur formulation (ratio, intégration de constante, complexification des formules) présentent l'intérêt d'être plus spécifiques au statut azoté que les longueurs d'onde étudiées individuellement.

Le **chapitre 2** présente 2 pistes explorées dans le but d'améliorer le suivi du statut azoté par télédétection. Tout d'abord le calcul de nouvelles combinaisons de longueurs d'onde afin d'identifier une formulation et des longueurs d'onde plus sensibles aux changements de statut azoté de la culture. Pour cela, les mesures de réflectances prises dans 15 longueurs d'onde ont été combinées entre elles en utilisant la formulation de 8 IV. Le fait d'avoir des mesures dans 15 longueurs d'onde nous a permis de tester différentes combinaisons pour chaque IV ; une couleur utilisée dans une formule pouvant correspondre à plusieurs longueurs d'onde parmi les 15 mesurées. En pratique, cela a représenté 248 combinaisons testées. Des régressions linéaires simples ont été effectuées pour chacune des 248 combinaisons afin de sélectionner celles réduisant l'erreur de prédiction du statut azoté du couvert.

Dans un second temps, différents modèles de prédiction non-paramétriques ont été testés afin d'améliorer le suivi du statut azoté. Ces modèles ont été validés en utilisant par date de mesure 25% du jeu de données mis de côté préalablement à cet effet. Enfin, pour le stade deux nœuds, commun aux deux années, la performance de chaque modèle a été testée en utilisant les données issues d'un jeu de données indépendant.

Ce **deuxième chapitre** présente cette démarche exploratoire ainsi que les résultats obtenus sur les données collectées sur deux parcelles d'essai présentant un gradient de fertilisation azotée, en 2020 à Savy (62) et Fréwillers (62) en 2021.

Les résultats obtenus dans le cadre de ce chapitre sont en préparation en vue d'une soumission pour publication dans la revue *Remote Sensing*.

Comparative analysis of parametric and non-parametric models to assess and predict the nitrogen nutrition index (NNI) during winter wheat growth using UAV-based multispectral images

Bouchard Marie-Astrid^{1*}, Vandoorne Bertrand¹ and Andriamandroso A.L.Herinaina¹

¹Université de Liège, Junia, UMRT 1158 BioEcoAgro - Conduction, optimization and design of cropping systems meeting multi-criteria objectives, B-5030 Gembloux, Belgique

*Correspondence: marie-astrid.bouchard@junia.com

Abstract

The rapid and nondestructive prediction of crop nitrogen (N) status based on unmanned aerial vehicle (UAV) imagery is of interest for precise N management. Assessing N status in real-time is important for adapting the N fertilizer rate in order to increase the N use efficiency (NUE) and minimize the N pollution in the environment, while maintaining high crop yield and satisfactory quality at harvest. The objectives of this study are (i) to test if the use of vegetation indices (VI) formulation by incorporating new wavelengths improves the correlation and prediction of the winter wheat nitrogen nutrition index (NNI), and (ii) to evaluate the ability of different modeling algorithms to assess wheat N status at two growing stages per year. During two growing seasons (2020 and 2021), two fields showing various patterns of NNI dynamics were monitored in the North of France. Measurements taken at 15 wavelengths made it possible to calculate eight VI, with a total of 248 different wavelength combinations. These combinations were evaluated to assess their predictive capacity. In a second phase, four modeling algorithms were tested, to improve NNI prediction by considering more VI. Partial Least Squares (PLS) and Principal Component Regression (PCR) models seemed to be the most suitable models for predicting N status from remotely sensed measurements. Our results indicate that these models present a relevant application as they performed equally or better compared to the best VI combination. Best results were obtained at beginning elongation, which present interesting perspectives for real-time based fertilization management.

Keywords: Nitrogen Nutrition Index, nitrogen fertilization, remote sensing, unmanned aerial vehicle, vegetation index, winter wheat, non-parametric regression model

1. Introduction

1.1. Monitoring N-status by remote sensing

1.1.1. Leaf optical properties and their relationship with physical and biological characteristics

It is known that leaf can reflect or absorb light according to its physical and biological characteristics. The intensity of these phenomena depends on the wavelength [1]. This makes it possible to characterize the vegetation status by reflection, absorbance, and transmission of the incident light [2]. In the visible spectral range (VIS, 450-670nm), the leaf reflectance is low due to a large absorption of incident light by the pigments. However, a slight reflectance peak can be observed in the green region (about 550nm). In the near infrared range (NIR, 800-1000nm), the reflectance is the highest, reaching almost 50% [1].

Reflectance is also qualitatively and quantitatively different between healthy and deficient plants [1]. Some wavelengths were identified as being more sensitive in N-status change. On one hand, in case of N deficiency, there will be more reflectance in the VIS and less reflectance in the NIR [4-5]. On the other hand, in case of N-status increase, reflectance showed a positive response in NIR and a negative response in VIS [3]. Recent studies have highlighted the interest of Red-Edge (between 680 and 780nm), a narrow region between VIS and NIR, to detect N content regardless of water stress [6-8]. In their review, Padilla et al. [4] summarize the most sensitive wavelengths to N status, according to their importance: the red absorption maxima (675nm), the NIR reflectance peak (905nm), the middle portion of the RedEdge (720nm) and the green reflectance maxima (550nm).

To increase sensitivity to changes in biophysical parameters while decreasing variability due to external factors, vegetation indices (VI) based on spectral reflectance measurements have been developed by combining light reflectance in different wavelengths [9]. Both the choice of wavelengths and the formulation of VI play an important role in the estimation of the N-status [10]. In fact, the formulation of VI with ratio and normalized differences could limit the influence of atmospheric and background (soil cover) differences between measurements [3].

So far, a range of VI has been proposed to predict wheat growth and N status: studies correlated UAV-based VI with biomass [11-14], canopy N content ($\text{g}\cdot\text{m}^{-2}$) [11,16,10], leaf N content ($\text{g}\cdot\text{m}^{-2}$) [10], canopy N concentration (%N) [11,14,17], leaf N concentration (%N) [15], N uptake [18] or NNI (N nutrition index) [12,14,18].

1.1.2. Indirect estimation of nitrogen nutrition index (NNI)

NNI is defined by Justes et al. [19] as the ratio of measured N concentration (%N) and the critical N concentration (%N_c) for a defined dry biomass (DM). %N_c is the minimum concentration necessary to achieve the maximum growth. It is recognized as a relevant N status indicator during the growing season [20-22]. Because it considers both N concentration and biomass. However, to date, few studies have focused on UAV-based NNI monitoring [10,12].

NNI estimation by remote sensing is still highly variable and VI performances depend on the measurement conditions, such as site, cultivars, growth stage and years [10,12], and are impacted by the simultaneous occurrence of stress [7]. Moreover, estimations are mostly based on single VI used to construct the N status prediction model [16], which means that only a few wavelengths are used [17]. The strong dependence of the VI on external elements and the use of the small portion of the spectrum highlight the difficulty in obtaining a unified model to predict N status in a wide range of situations [17].

1.1.3. Improving N-status prediction using models

To overcome poor VI prediction capacity in a wide range of situations, studies are looking at the predictive capacity of modeling algorithms that consider multivariable inputs, for example by combining different VI [10,16,17,23,24]. Considering that reflectance measurements are highly correlated between different wavelengths, stepwise multiple linear regression suffers from multicollinearity and results in inconsistent models [23]. However, different modeling algorithms are relevant to predict N status from remote sensing measurements:

1. Ridge regression is a penalized regression, whose objective is to improve the model's prediction quality by decreasing parameters variance while limiting the bias [25]. Makowski et al. [25] underlines the fact that penalized regression principles are close to linear regression and therefore provide easily interpretable regression coefficients.

2. In the case of correlated variables, principal component regression (PCR) and partial least squares regression (PLS) are preferred [25]. They allow the dimensions of the variables to be reduced by replacing the explanatory variables to fewer non-correlated principal components [25-26]. The new independent variables are defined by Principal Component Analysis (PCA) in the case of PCR and by correlation to the response variable for PLS [25]. Thus, these methods are suitable for remote sensing measurements as the reflectivity in different wavelengths are often correlated. Moreover, these methods are adapted when the number of variables in the dataset exceeds the number of individuals [17,25].

3. Finally, random forest (RF) modeling methods consist of a succession of decision rules to explain or predict a response variable [25]. Each decision is based on the most discriminating variable, creating new samples for which a new decision rule is applied up to a fixed number of levels.

Several studies highlighted that modeling offers good opportunities to predict N status. According to Zheng et al. [10] models are more efficient and less specific than VI alone because more wavelengths combinations are allowed. Among different modeling algorithms evaluated to predict wheat N status, RF was the best performing algorithm ($R^2=0.79$, Root Mean Square Error (RMSE) cross validation=0.33) in the study of Zheng et al. [10], Particle Swarm Optimization-based Support Vector Regression model (PSO-SVR) for Yang et al. ($R^2_{\text{training-validation}}=0.797-0.9025$, $RMSE=0.3287-0.4415$) [16]. Li et al. [17] and Hansen and Schjoerring [26], have shown a relevant application of PLS regressions. They both observed better performance with PLS models compared to the best independently studied VI [17, 26]. For Li et al. [17], R^2_{training} for PLS model increased by 76.8% compared to the R^2 obtained with the best performing VI to predict canopy N concentration. Finally, Hansen and Schjoerring highlighted an increase from 0.56 (R^2_{training} best performing VI) to 0.71 for PLS models to estimate leaf N content [26]. Because non-parametric algorithms can consider complex and numerous data most of the studies are done with measurements taken by hyperspectral camera. These cameras are mainly used by proximal sensing, thus there are less studies work on non-parametric models based on UAV-measurements [24, 51].

In this context, the main objectives of this study were: (i) to test if the use of VI formulation by incorporating new wavelengths improves the correlation and prediction of NNI, and (ii) to evaluate and compare the ability of different modeling approaches to assess N status at 2 growing stages per year.

2. Materials and Methods

2.1. Experimental sites and fertilization rates

The study was carried out on winter wheat in the North of France (Pas-de-Calais department, 62) during two growing seasons (2019-2020 and 2020-2021). Two wheat crop experiments showing various patterns of NNI dynamics were monitored, representing different combinations of total N fertilizer levels and splitting strategies. In each site, the experiment was conducted in a randomized block design comprising 13 treatments and six replicates in 2020 and 20 treatments and four replicates in 2021 (Table 1 and 2). In 2020, trial zone represents 78 microplots of 27.5 m², and in 2021 80 microplots of 26.3 m², implemented in a homogeneous area of a field of 11.2 ha in 2020 and 5.8 ha in 2021. Each treatment represented a fertilization strategy. Fertilization strategies were compared with two control treatments: an unfertilized control and the Reference dose (R) calculated according to the balance sheet method (Comifer et al., 2013).

For the 2020 season, the Chevignon variety (Saaten Union, 2017, France) was sown on October 24th, 2019. For the 2021 experiment, a varietal mixed was sown on October 20th, 2020. The varietal mixed included Chevignon (Saaten Union, 2017, France), KWS Extase (KWS Momont, 2018, France) and Winner (Florimond Desprez, 2018, France) varieties, in proportions of one third of each. N applications were made with 27% ammonium nitrate.

Table 1 : Site location, previous crop, soil mineral N content at 90cm measured at the end of winter and fertilizer rates at Savy (2020) and Frevillers (2021) experimental sites

Trial	Location, degrees	Previous crop	Soil mineral N content at 90cm (kg N.ha⁻¹)	Fertilization gradient (kg N.ha⁻¹)	Reference rate RR* (kg N.ha⁻¹)
Savy	50°20'36.2"N 2°33'02.3"E	Rapeseed	91	0-315	180
Frevillers	50°23'41.3"N 2°32'08.5"E	Sugar beet	128	0-300	130

*calculated according to the balance sheet method [27]

Table 2 : Fertilization strategies: N fertilizer rates in kg N.ha⁻¹, reported per Zadoks growth scale [28] in 2020 (a) and 2021 (b). The bold line corresponds to the reference dose calculated according to the balance sheet method [27]

(a) Input	Z29	Z31	Z32	Z39	(b) Input	Z21	Z29	Z31	Z32	Z39	Z59
Control	0	0	0	0	Control	0	0	0	0	0	0
RR-80	20	60		20	RR-80		20	10		20	
RR-40	40	60		40	RR-40		40	30		20	
(RR)	40	100		40	(RR)		40	50		40	
RR+40	40	100	40	40	RR+40		40	50	40	40	
RR+80	60	100	40	60	RR+80		60	50	40	60	
2020_1	60	60		60	2021_1	40		50		40	
2020_2	80	40		60	2021_2	20	40	30		40	
2020_3	30	30		30	2021_3		80	50			
2020_4	105	105		105	2021_4		80	30		20	
2020_5	80	100			2021_5			70		60	
2020_6		80	40	60	2021_6		40+30S	50		40	
2020_7	40	100		40	2021_7		40+40P	50		40	
					2021_8		40	50		40	
					2021_9		40	30		40	20
					2021_10		40	30		40	20
					2021_11		30	30		30	
					2021_12		60	60		60	
					2021_13		80	80		80	
					2021_14		100	100		100	

S:Sulfur and P:Phosphorus

Normal rainfall (1981-2010) over the study areas averages 743mm per year, but the first years studied (2020) have been particularly dry, with up to 15% less rainfall, while in 2021 rainfall was above normal. During the wheat fertilization period (March to June), these differences reached -24% in 2020 and +4% in 2021 (Table 3).

Table 3 : Monthly rainfalls (mm) for Lille-Lesquin weather station in 2020 and 2021 and between 1981 to 2010 (MeteoFrance)

	Jan.	Feb.	March	April	May	June	July	August	Sept.	Oct.	Nov.	Dec.
2020	29.5	92.3	63.3	41.1	4.2	72.2	25	64.1	7.6	109	37.1	83.3
2021	114.5	35.8	32.2	25.9	78.2	109.8	78	76.5	36.8	101.5	62.6	46
Normals*	60.5	47.4	58.3	50.7	64	64.6	68.5	62.8	61.6	66.2	70.1	67.8

*normals calculated from 1981 to 2010

At harvest, yield ranged from 5.17 Mg.ha⁻¹ (Control) to 9.58 Mg.ha⁻¹ (2020_2) in 2020 and from 3.28 Mg.ha⁻¹ (Control) to 8.91 Mg.ha⁻¹ (2021_4) in 2021. Mixed analysis of variance (ANOVA) with Tukey's multiple comparison procedure was performed to evaluate the influence of fertilization at harvest. A p-value of 0.05 was applied to differentiate the means of the N treatments and fertilization had a significant effect for the 2 years of study (p-value <0.001 in 2020 and p-value =0.0037 in 2021).

2.2. Crop analysis and ground level measurements

Measurements were taken at two Zadoks growth stages: Z32 (second node detectable) and Z39 (flag leaf ligule just visible) in 2020. For 2021, Z32 and Z45 (swelling) stages were monitored [28].

To find a correlation between crop N status and remote sensing measurements of reflectance, the N concentration (%N) was measured on the aerial part. Biomass samples were collected in a row of 50 cm in each plot and dried in an oven at 65°C. After each sample had been finely ground, the N concentration was measured on the aerial part using the Dumas method (NF EN ISO 16634-1). The dry biomass per unit area was calculated using the number of plants counted on 1 m² area. NNI was then calculated using (Eq. 1), as the ratio of measured N concentration (%N) and the critical N concentration (%N_c) for a defined dry biomass (DM). For winter wheat, N_c is obtained using (Eq. 2) [19].

$$\text{NNI} = \%N/\%N_c \quad (\text{Eq. 1})$$

$$\text{for } DM < 1.55 \text{ T} \cdot \text{ha}^{-1} \%N_c = 4.4, \text{ for } DM > 1.5 \text{ T} \cdot \text{ha}^{-1} \%N_c = 5.35DM^{-0.442} \quad (\text{Eq. 2})$$

2.3. UAV image acquisition and processing

The UAV images were acquired with a six-lens multispectral modular camera (Kernel camera, Mapir, San Diego, CA, USA) mounted on M1Agri UAV (ADT drones, Soissons, France) (Figure 1). With the Mapir Kernel camera, it was possible to equip the 6 different filters among 15 possible wavelengths: 405nm (±50nm), 450nm (±50nm), 490nm (±75nm), 518nm (±50nm), 550nm (±50nm), 590nm (±50nm), 615nm (±75nm), 632nm (±50nm), 650nm (±50nm), 685nm (±50nm), 725nm (±50nm), 780nm (±50nm), 808nm (±50nm), 850nm (±100nm), 940nm (±200nm). UAV flights were made at a height of 30m in favourable conditions. Using the six lenses, three flights per stage were required to obtain images in 15 wavelengths.




Figure 1 : Pictures of M1Agri UAV, the Kernel camera on the UAV (dismantled to change the filters between flights) and the Mapir calibration target

Calibrations were made according to Mapir Camera Control software thanks to images of the Mapir calibration target. After image calibration, orthomosaic map in each wavelength studied were generated using Pix4D software (Pix4D S.A., Prilly, Switzerland). The reflectance maps for each wavelength were then processed in QGIS (QGIS Development Team 2021, version 3.10) to extract the median reflectance per microplot. The median value was used instead of the mean in order to consider vegetation reflectance and reduce the soil effect. The data exported from QGIS were analysed with RStudio (RStudio Team 2019, version 3.6.2).

2.4. Data analysis

Initially, mixed analysis of variance (ANOVA) with Tukey’s multiple comparison procedure was performed stage by stage to evaluate the influence of fertilization on NNI. The goal was to test the following hypothesis: (H0) there are no differences between the treatments. A p-value of 0.05 was applied to differentiate the means of N treatments. In addition, coefficient of variation was calculated as the ratio of the standard deviation to the mean, for NNI at stage Z32 (2020-2021), Z39 (2020) and Z45 (2021).

2.4.1. NNI determination by different algorithms: model training and cross-validation
For UAV-based measurements, different wavelength combinations were calculated using the formulation of eight VI. The eight indices were chosen to have varying levels of complexity and use different wavelengths. With the 15 available wavelengths, a total of 248 combinations were calculated each year (Table 4).

The dataset for 2020 and 2021 were divided by stage using RStudio caret package [29]: 75% of the data were randomly selected as the training data set, while the remaining 25% were used for validation (Figure 2, yellow inset “data”).

In order to set aside combinations with little interest and identify the best performing combinations, simple linear regression between NNI and all combinations were made one by one. Combinations of interest were selected according to their RMSE (Eq. 3) in two ways: on the one hand, the combination minimizing the RMSE per VI formulation. Because some VI are less able to predict N status, on the other hand, combinations were selected according to a threshold RMSE regardless of the VI formulation. For this, about 15% of the combinations were retained to set aside combinations with lowest interest. In a second step, the pls [36], glmnet [37] and randomForest [38] packages were used to train the Ridge, Partial Least Squares Regression (PLS), Principal Component Regression (PCR) and Random Forest (RF) models with the previously selected combinations (Figure 2, blue inset “model training”). Models training was done on training dataset to adjust the model parameters. For RF, the number of trees was fixed in order to stabilize the out-of-bag error (root mean square error on the out-of-bag individuals, i.e. the individuals in the test sample as opposed to the individuals in the training sample) [25]. For PLS and PCR, to avoid overfitting, the number of components has been chosen to limit prediction error by minimizing the Predicted REsidual Sum of Squares (PRESS) [25].

The performance of the previously created models was validated firstly in terms of RMSE (Eq. 3), bias (Eq. 4) and determination coefficient (R^2 , Eq. 5) using the ZeBook package [39] with Leave-One-Out Cross-Validation. With n is the number of observations in the dataset, y_i the measured values, \bar{y} the means, and \hat{y}_i the predicted values.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (\text{Eq. 3})$$

$$Bias = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)}{n} \quad (\text{Eq. 4})$$

$$R^2 = 1 - \left[\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \right] \quad (\text{Eq. 5})$$

Table 4: Calculated combinations and wavelengths used according to the IV formulation (R: Red, G: Green, NIR: Near Infrared, RE: RedEdge)

		Wavelengths (nm)												
VI	Formulation	Reference	550	590	615	632	650	685	725	780	808	850	940	
NDVI	Normalized Difference Vegetation Index	$(NIR-R)/(NIR+R)$				R	R	R	R+NIR	NIR	NIR	NIR	NIR	
GNDVI	Green Normalized Difference Vegetation Index	$(NIR-G)/(NIR+G)$	[31]	G	G	±G			NIR	NIR	NIR	NIR	NIR	
MCARI	Modified Chlorophyll Absorption Reflectance Index	$[(NIR-R)-0.2 \times (NIR-G)] \times (RE/R)$	[32]	G	G		R	R	R	R+NIR	NIR	NIR	NIR	
NDRE	Normalized Difference Red Edge	$(NIR-RE)/(NIR+RE)$	[33]						RE	RE	NIR	NIR	NIR	
OSAVI	Optimized Soil Adjusted Vegetation Index	$(NIR-R)(NIR+R+0.16)(NIR-R)/(NIR+R+0.16)$	[34]				R	R	R	R+NIR	NIR	NIR	NIR	
TCARI	Transformed Chlorophyll Absorption in Reflectance Index	$3 \times [(RE-R)-0.2 \times (RE-G)] \times (RE/R)$	[32]	G	G	R	R	R	R+RE	RE	RE			
NG (GRVI)*		NIR/G	[35]	G	G	±G				NIR	NIR	NIR	NIR	
TCARI/OSAVI				G	G	R	R	R	R+RE	RE	RE	NIR	NIR	

*Different formulas according to the studies

2.4.2. Model validation and testing on an independent dataset

After training on the training dataset, the models were validated using the validation dataset. The predictive capability was, then, assessed using the determination coefficient (R^2) (Figure 2, green inset “model validation”). Finally, the most relevant models were tested on the 2021 dataset for the 2020 models and vice versa to use an independent dataset (Figure 2, light blue inset “model testing”).




Figure 2 : Diagram of the analysis approach used in chapter 3 (NNI: Nitrogen nutrition index, VI: vegetation index, RF: random forest, PCR: Principal Component Regression, PLS: Partial Least-Square regression). The yellow inset represents data acquisition and partitioning to train (blue inset) and validate models (green inset). After validation, the model of interest is tested on an independent data set (another year, light blue inset)

3. Results

3.1. NNI dynamics in 2020 and 2021




Figure 3 : Average NNI per fertilization strategy according to studied stage for Savy 2020 (a) and Frevillers 2021 (b) (bars represent standard deviations), the horizontal line represents NNI=1 which is the critical INN according to Justes et al. (1994). RR=180 kg N.ha⁻¹ in 2020 and RR=130 kg N.ha⁻¹.

In 2020, measured NNI values ranged from 0.415 (Control-Z32) to 1.40 (RR+40-Z39) (Figure 3). In 2021, NNI levels were lower and varied from 0.359 (Control-Z45) to 1.02 (2021_14-Z45), most of the NNI values were lower than one. For all measurements dates, fertilization practices had a significant effect on NNI (p-value <0.05). Between the two sites and between the two years, at stage Z32, the differences in NNI were more pronounced in Frevillers than in Savy, coefficients of variation were 27% and 15% respectively. The opposite was observed between Z39 and Z45, coefficient of variation was 29% for Savy and 27% for Frevillers.

3.2. Correlation analysis between individual wavelength combinations and NNI

From the 248 wavelength combinations calculated for eight VI formulations, simple linear regressions were performed to identify the VI and wavelengths of interest. The selection was made according to RMSE per VI formulation on the one hand and regardless of the VI formulation on the other hand.

3.2.1. Combination selection according to RMSE per VI

Table 5 presents the combinations that minimise the RMSE and the associated wavelengths by VI formulation and by sampling date. Among the 8 indices tested, the GNDVI was the one that minimised the RMSE in 2020 for the two sampling dates. While in 2021, it was the NG (ratio NIR/G) at stage Z32 and TCARI/OSAVI at stage Z39. However, NG also seemed relevant at stage Z39 with an RMSE very close to the best combination. Even if the same VI tended to emerge by year, they were not made with the same combinations of associated wavelengths. However, at Z32, the most interesting wavelengths for GNDVI and NG, 940nm and 550nm, were the same between the two years despite the different

VIs' formulation. Finally, among the wavelengths present in the combinations with the lowest RMSE, 780nm was the most represented. On the contrary, for all stages and years, NDRE is the formulation with the worst RMSE.

Table 5 : Combinations minimizing the RMSE per VI formulation for linear regressions with NNI: RMSE minimum and wavelength related for each tested formulation (values and combinations underlined are those that minimize the RMSE per VI formulation)

VI Formulation	2020-Z32		2020-Z39		2021-Z32		2021-Z45	
	RMSE minimum	Wavelength combination (nm)	RMSE minimum	Wavelength combination (nm)	RMSE minimum	Wavelength combination (nm)	RMSE minimum	Wavelength combination (nm)
NDVI	0.169	632_780	0.205	650_780	0.152	632_940	0.141	685_940
GNDVI	<u>0.164</u>	<u>940_550</u>	<u>0.198</u>	<u>780_615</u>	0.144	940_550	0.137	940_590
MCARI	0.173	780_632_590	0.205	850_685_590	0.147	940_632_590	0.136	780_685_550
NDRE	0.186	725_940	0.254	725_808	0.159	780_850	0.143	725_808
OSAVI	0.169	632_780	0.205	650_780	0.152	632_940	0.141	685_940
TCARI	0.166	780_632_550	0.224	725_650_590	0.148	780_632_550	0.135	780_685_590
NG	0.166	940_550	0.214	780_615	<u>0.138</u>	<u>940_550</u>	0.1334	808_590
TCARI/OSAVI	0.165	780_632_550_725_850	0.206	725_650_590_725_808	0.146	780_632_590_685_725	<u>0.1330</u>	<u>780_685_590_685_725</u>

The linear relationship between NNI and combinations minimizing RMSE were studied for GNDVI in 2020 and NG in 2021. Table 6 presents the coefficients of determination (R^2) obtained per stage on the training dataset, on the validation dataset and on the 2021 dataset for the 2020 models (or vice versa). For stage Z32, the VIs performed well on the validation dataset ($R^2_{validation}=0.88$ in 2020 and 0.72 in 2021) while NNI prediction quality was average on the other year's dataset ($R^2=0.46$ for 2020 model on 2021 dataset and 0.39 for 2021 model on 2020 dataset). The trend was not the same between Z39 and Z45, the best VI in 2021 provides a better estimate of the NNI observed in 2020 than the reverse.

Table 6 : Coefficients of determination (R^2) of the linear relationship between NNI and combinations minimizing RMSE per stage for (a) 2020 and (b) 2021, on the training ($R^2_{training}$), validation ($R^2_{validation}$) and other year dataset

(a)		2020			(b)		2021		
Stage	VI Formulation	$R^2_{training}$	$R^2_{validation}$	R^2_{2021}	Stage	VI Formulation	$R^2_{training}$	$R^2_{validation}$	R^2_{2020}
2020-Z32	GNDVI 940-550	0.36	0.88	0.46	2021-Z32	NG 940-550	0.47	0.72	0.39
2020-Z39	GNDVI 780-615	0.56	0.49	0.33	2021-Z45	NG 808-590	0.48	0.38	0.51

3.2.2. Combination selection according to RMSE regardless of the VI formulation

As highlighted above, some VI formulations did not seem to be particularly relevant for estimating NNI in our case. Thus, combination analysis regardless of the VIs formulation by setting a threshold RMSE was interesting. Between 12% (2021-Z32, RMSE threshold=0.15) and 17% (2020-Z32, RMSE threshold 0.17) among all combinations calculated were selected (Table 7).

Table 7 : Percentage of indices selected with the RMSE limit among all combinations calculated per VI formulation (number of selected combinations)

VI (Number of combinations calculated)	2020-Z32 (Threshold RMSE=0.17 42 combinations)	2020-Z39 (Threshold RMSE=0.22 34 combinations)	2021-Z32 (Threshold RMSE=0.15 29 combinations)	2021-Z45 (Threshold RMSE=0.14 31 combinations)
NDVI (19)	16% (3)	32% (6)	0%	5% (1)
GNDVI (15)	33% (5)	27% (4)	7% (1)	40% (6)
MCARI (38)	5% (2)	13% (5)	11% (4)	16% (6)
NDRE (6)	0%	0%	0%	0%
OSAVI (19)	16% (3)	32% (6)	0%	5% (1)
TCARI (16)	13% (2)	0%	13% (2)	13% (2)
NG (15)	27% (4)	13% (2)	47% (7)	53% (8)
TCARI/OSAVI (118)	20% (23)	9% (11)	13% (15)	6% (7)

In terms of selected combinations, a similar trend as before was partially found in our case; NDRE had a low interest and NG seemed to have a high interest in 2021. For 2020, the trends were less obvious, GNDVI was the most represented in terms of percentage of selected combinations at Z32 while, at Z39, it was NDVI and OSAVI.

Table 8 shows the occurrence of wavelengths among the selected combinations according to RMSE. For all studied dates, the wavelengths that were the most present among the combinations that minimize RMSE were the same: 780nm and 590nm, even if it was less pronounced at Z39 (2020). At stage Z32, 632nm was well represented both years.

Table 8 : Occurrence of each wavelength within the selected combinations according to RMSE regardless of the Vis formulation (occurrences above 14 are underlined)

Wavelengths (nm)	2020-Z32 (Threshold RMSE=0.17 42 combinations)	2020-Z39 (Threshold RMSE=0.22 34 combinations)	2021-Z32 (Threshold RMSE=0.15 29 combinations)	2021-Z45 (Threshold RMSE=0.14 31 combinations)
550nm	7	4	7	11
590nm	<u>28</u>	<u>14</u>	<u>20</u>	<u>18</u>
615nm	1	4	2	0
632nm	<u>24</u>	5	<u>22</u>	0
650nm	<u>16</u>	<u>17</u>	6	3
685nm	8	13	8	<u>21</u>
725nm	8	<u>20</u>	2	2
780nm	<u>40</u>	<u>16</u>	<u>24</u>	<u>15</u>
808nm	9	5	5	8
850nm	11	8	5	3
940nm	7	4	7	11

3.3. Validation of different NNI prediction models

3.3.1. Cross-validation

Four regression algorithms were tested from the previously selected combinations, on the one hand the combinations that minimize the RMSE per VI (eight combinations) and on the other hand with the combinations regardless the VIs formulation (between 29 2021-Z32 and 42 combinations 2020-Z32).

Table 9 : RMSE and bias for the four different models tested (Ridge, PCR, PLS, RF), constructed with the best combinations minimizing the RMSE, selected per VI or regardless of the VI formulation in 2020-Z32, 2020-Z39, 2021-Z32 and 2021-Z45 (lowest RMSE values were underlines)

Model	RMSE	Bias
2020-Z32		
Ridge-best combination per VI	0.1617	-2,22E-16
PCR-best combination per VI	0.1649	-5,43E-04
PLS-best combination per VI	0.1649	-5,48E-04
RF-best combination per VI	0.1903	-9,17E-03
Ridge-best combination regardless of the VI formulation	0.1653	-1,11E-16
PCR- best combination regardless of the VI formulation	0.1585	-1,34E-04
PLS- best combination regardless of the VI formulation	<u>0.1581</u>	-2,10E-04
RF- best combination regardless of the VI formulation	0.1804	-6,16E-03
2020-Z39		
Ridge-best combination per VI	0.1892	1,11E-16
PCR-best combination per VI	<u>0.1577</u>	-5,45E-04
PLS-best combination per VI	<u>0.1577</u>	-5,45E-04
RF-best combination per VI	0.2076	-7,98E-04
Ridge-best combination regardless of the VI formulation	0.1948	1,11E-16
PCR- best combination regardless of the VI formulation	0.1675	1,26E-03
PLS- best combination regardless of the VI formulation	0.1689	1,30E-03
RF- best combination regardless of the VI formulation	0.2157	-2,89E-03
2021-Z32		
Ridge-best combination per VI	0.1345	-1,11E-15
PCR-best combination per VI	0.1303	2,50E-04
PLS-best combination per VI	<u>0.1302</u>	2,66E-04
RF-best combination per VI	0.1636	-8,38E-03
Ridge-best combination regardless of the VI formulation	0.1369	-4,44E-16
PCR- best combination regardless of the VI formulation	0.1392	-1,07E-03
PLS- best combination regardless of the VI formulation	0.1424	1,90E-05
RF- best combination regardless of the VI formulation	0.1654	2.82E-04
2021-Z45		
Ridge-best combination per VI	0.129	2.22E-16
PCR-best combination per VI	0.1322	1.12E-03
PLS-best combination per VI	0.1322	1.12E-01
RF-best combination per VI	0.1495	1.83E-03
Ridge-best combination regardless of the VI formulation	<u>0.1265</u>	2.22E-16
PCR- best combination regardless of the VI formulation	0.1415	3.75E-03
PLS- best combination regardless of the VI formulation	0.1385	2.33E-03
RF- best combination regardless of the VI formulation	0.1627	-3.08E-03

On average and at equivalent stages, the RMSE was lower in 2021 than in 2020, while the bias is smaller in 2020 than in 2021 (Table 9). In 2020, the average RMSE was lower at Z32 than at Z39 and the opposite was observed for the bias. In 2021, the average RMSE was equivalent between the 2 dates, but the bias was higher at Z39. The analysis of each date independently highlighted that PLS models minimized the RMSE, even if the selection of input variables was not always done in the same way, except at stage Z45. Except for RMSE at stage Z32 in 2020, models with the best combinations per VI allowed a reduction in the prediction error compared to the models with the combinations regardless of the VIs formulation. The bias was minimized, for all stages, by the Ridge model. On the contrary,

apart for the PLS and PCR model-bias at Z39 and Z45, the RF models had the worst performances at stage Z32.

3.3.2. Models validation

Figure 4 presents the R^2 obtained by leave-one-out cross-validation on the training dataset (R^2) and with the 25% of the dataset that had been set aside for this before models' training (R^2 validation).




Figure 4 : R^2 on the training dataset by leave-one-out cross validation and on the validation dataset (R^2 validation) for the four different models tested (Ridge, PCR, PLS, RF), constructed with the best combinations minimizing the RMSE, selected per VI or regardless of the VI formulation in 2020-Z32 (a), 2020-Z39 (b), 2021-Z32 (c) and 2021-Z45 (d). “per VI” refers to models constructed with the combinations minimizing the RMSE for each VI formulation, “regardless the VI” refers to models constructed with the combinations minimizing the RMSE regardless of the VI formulation and selecting according to a threshold RMSE.

The major difference observed between stages Z32 and Z39-45 was that R^2 on the training dataset was higher than R^2 validation at stages Z39 and Z45, while the opposite was observed at Z32. This highlights an overfitting of the models at stages Z39 and Z45. This problem was also observed for RF models for all dates.

Concerning R^2 validation, a better prediction quality was obtained at Z32 compared to Z39 and Z45 for the 2 years studied. The date-by-date analysis shows that, except for RF, the Ridge model provided the best R^2 validation in 2020 and at stage Z45 in 2021 (up to 0.892 at Z32 in 2020). In 2021, at Z32 stage, the PCR model with the best combinations per VI had the best R^2 validation (0.721). In general, except for RF at all stages and Ridge models in 2021 at Z32, the predictive quality was better when the models were built from the best combinations per VI rather than regardless of the VI formulation. This was due to the different number of variables.

To conclude, at the Z39 and Z45 stages, all the models suffered from overfitting. At Z32, apart from RF, which did not seem to be suitable with our data as this model was overfitting in all situations, the models looked promising however the trends observed at this stage were not the same between 2020 and 2021.

3.4. Models testing

The eight models were tested, on the one hand with 2021 data for models created with the 2020 dataset and on the other hand on 2020 data for models created with the 2021 dataset.

3.4.1. Testing 2020 models on the 2021 dataset

Of all the 2020 models tested on the 2021 dataset, the Ridge models obtained the best prediction quality (Figures 5 and 6). However, in terms of the order of magnitude of the predicted NNI values, these were significantly overestimated. On the contrary, the RF models were the least suitable for our data: R^2 were low and the models were not able to predict the different levels of NNI. The PCR and PLS models gave intermediate results to the previous ones: the R^2 was average and the same as the models were created with the bests wavelengths combinations by VI or regardless of the VI formulation. However, the models created with the best combinations per VI allowed for consistent predicted NNI values, whereas models created with combinations regardless of the VI formulation tended to overestimate the predicted NNI values. In general, the performances of the 2020 models applied to the 2021 data remained average.

3.4.2. Testing 2021 models on the 2020 dataset

The prediction quality of the 2021 models tested on 2020 data was worse than that of the 2020 models. The trends observed for the 2020 models were retained here for the 2021 models (Figures 7 and 8). The best R^2 was obtained with the Ridge models, while the predicted NNI values were inconsistent because they were negative. As highlighted before, RF models were poorly performing and not adapted to the data. For 2021 models, the prediction quality differed for the PCR and PLS models depending on the combinations of which they are composed: models with the bests combinations per VI performed better than models with the best combinations regardless of the VI formulation. In general, except for PCR models with the best combinations regardless of the VI formulation, 2021 models underestimated NNI values measured in 2020.




Figure 5 : NNI measured and predicted on the 2021 dataset using the 2020 Ridge (a), PCR (b), PLS (c), RF (d) models created with the combinations minimizing the RMSE per VI formulation at Z32 stage




Figure 6 : NNI measured and predicted on the 2021 dataset using the 2020 Ridge (a), PCR (b), PLS (c), RF (d) models created with the combinations minimizing the RMSE regardless of the VI formulation at Z32 stage

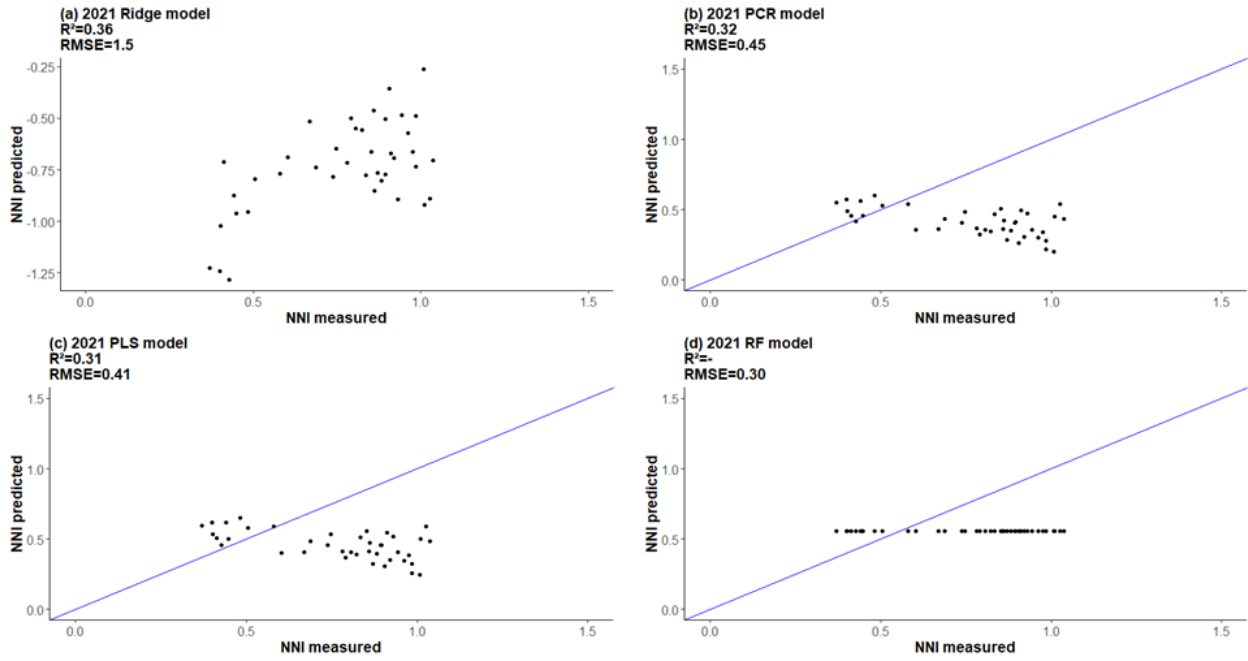


Figure 7 : NNI measured and predicted on the 2020 dataset using the 2021 Ridge (a), PCR (b), PLS (c), RF (d) models created with the combinations minimizing the RMSE per VI formulation at Z32 stage

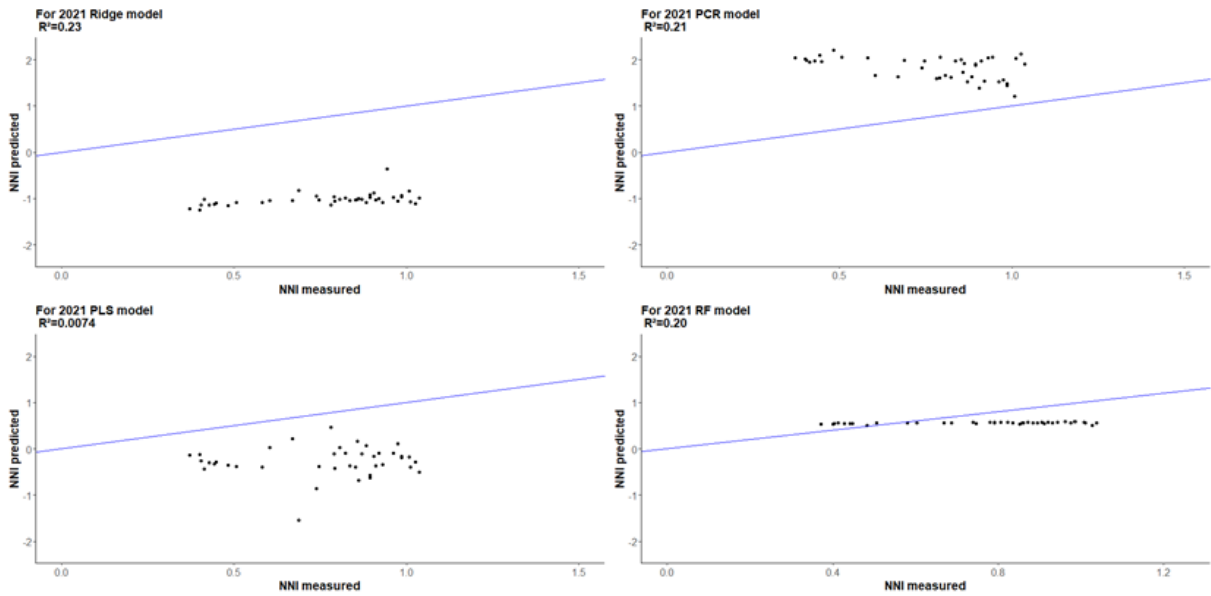


Figure 8 : NNI measured and predicted on the 2020 dataset using the 2021 Ridge (a), PCR (b), PLS (c), RF (d) models created with the combinations minimizing the RMSE regardless of the VI formulation at Z32 (one outlier for PLS model)

4. Discussion

NNI is a relevant indicator for monitoring N status because it considers the dilution effect which allows comparison of different crops' N status independently of their differences in crop biomass [40]. As demonstrated in other studies, it is sensitive to N inputs and can identify N deficiencies [19,41]. Measuring NNI directly is time consuming and destructive, therefore remote sensing offers good opportunities and allows consideration of spatial and temporal variability of N status (repeatable measurements). This study aimed to increase accuracy of NNI prediction by remote sensing, by testing new wavelength combinations from known VI formulations and evaluating the performance of four prediction models.

4.1. Monitoring NNI with UAV-based VI: wavelengths and VI of interest

4.1.1. Wavelength selection

The MAPIR Kernel camera used in the study allowed reflectance measurements in 15 wavelengths to be taken and thus to calculate 248 different combinations from 8 formulations. In the present work, the most sensitive wavelengths were 940nm (NIR), 780nm (end of the RedEdge), 632nm (beginning Red), 590nm (Amber) and 550nm (Green). This is consistent with the synthesis made by Padilla et al. [4] who highlighted 4 bands sensitive to change of chlorophyll status, in order of importance: 675nm (Red), 905nm (NIR), 720nm (mid-RedEdge) and 550nm (Green). However, in this study, in addition to Red, NIR, RedEdge and Green, the measurement in Amber (590nm) was of interest.

Among the eight formulations tested, in 2020, the GNDVI was the formulation that minimizes the RMSE while in 2021, NG performed well for the two stages studied. Although it was not the same formulation, these VI were both calculated with NIR and Green. At Z32 stage, GNDVI (in 2020) and NG (in 2021) were both formulated with 940nm and 550nm. 550nm, in Green, corresponds to a chlorophyll reflectance peak [3]. The significant correlation between chlorophyll and N concentration ($R^2=0.97$) explains its importance [40]. However, leaf reflectance is quite low in the visible range compared to NIR where the reflectance reaches 50% [1]. In the study the reflectance in the NIR was close between fertilised modalities, so 940nm in the best performing VIs seemed to exacerbate the differences in the associated wavelengths.

The VI associating NIR and Green appear in several studies to evaluate crop N status [3-4,11,16,26,44]. In their review, Padilla et al. [4] highlight the interest of VI based on reflectance in green and RedEdge as relevant crop N indicators. Using green instead of red allows more sensitivity to the whole range of chlorophyll content, especially at high chlorophyll levels where VI including red tends to saturate [4]. These results are interesting because these green-VIs seem to be able to detect N excess. Bao et al. [3] concluded on the interest of GNDVI (750nm-550nm) to follow the canopy N content (g.m^{-2}) of winter wheat (R^2 up to 0.89). For Quemada et al. [4] combinations including green reflectance were among the best VI for monitoring N content (g.m^{-2}) because NG and the combination of NG and NDVI allowed the best predictions (NG-NDVI: $R^2=0.58$ at stem elongation and NG: $R^2=0.71$ at flowering) to be obtained. Hansen and Schjoerring [26] found better correlation between green-VI and LAI (leaf area Index) than with N status.

As demonstrated in many other studies VI including Red and/or RedEdge are widely studied and seem to perform equally well or better in monitoring canopy N content (g.m^{-2}) [3,8,10,11,18], canopy N concentration (%N per dry biomass) [7,8,11,17], leaf N content (g.m^{-2}) [10,23,26], leaf N concentration (%N per dry biomass) [26] or NNI [11,18]. The RedEdge, between 670 and 800nm, increases the VI sensitivity compared to Red [23] and it is less sensitive than Red to saturation at high biomass levels

[26]. For example, Zheng et al. [10] combined five wavelengths according to 19 VI formulations. The best 2 bands-VI to monitor leaf N content ($\text{g}\cdot\text{m}^{-2}$) was RDVI and SAVI with NIR (800nm) and RedEdge (720nm) ($R^2=0.73$, $\text{RMSE}=0.38$). Argento et al. [18] also found the best correlation between VI and NNI with a combination including RedEdge (735nm) and NIR (790nm) (NDRE, $R^2=0.75$). It is consistent with this study, where 780nm, at the interface between RedEdge and NIR, was the most common wavelength present in the best combinations. However, in other studies, the middle RedEdge (720nm) was more responsive [3-4,10]. Rodriguez et al. [7] selected 750nm. Even if 780nm is widely present among the best combinations, in this study, NDRE, which combines RedEdge and NIR, poorly performed to predict NNI. This is consistent with the results from Quemada et al. [11], who observed the worst correlation between NNI and NDRE at stem elongation ($R^2=0.05$).

The wavelengths 632nm (beginning Red) and 590nm (Amber) are not widely studied in other works. In literature, the most measured Red wavelengths are 658nm (RapidEye, Koln, Deutschland), 660nm (Sequoia Camera, Parrot, Paris, France), 668nm (RedEdge-MX Camera, Micasense, Seattle, USA), 670nm (MCA-6 Camera, Tetracam, Chatsworth, USA) and 675nm (Airphen Camera, Hiphen, Avignon, France) [6,10-11,13,18,44]. Reflectance in Red wavelengths have been used in VI to predict canopy N content ($\text{g}\cdot\text{m}^{-2}$) [10,11,18], canopy N concentration (%N per dry biomass) [11], leaf N content ($\text{g}\cdot\text{m}^{-2}$) [10], leaf N concentration (%N per dry biomass) [44], NNI [11,18], LAI and yield [13] and to discriminate crop response to N fertilizer rates [6]. In fact, Red absorption maxima at 670-675nm correspond to chlorophyll absorption which is widely correlated with the crop N content ($\text{g}\cdot\text{m}^{-2}$) [3]. This is consistent with the widespread use of NDVI to monitor crops growth, combining measurements in the Red and NIR [25]. Quemada et al. [11] have studied NNI prediction from VIs and had the best correlation with RDVI ($R^2=0.37$ at elongation) and OSAVI ($R^2=0.61$ at flowering), these 2 indices combined Red (670nm) with NIR (800nm). Few works study the wavelength 590nm, except works using a Crop Circle ACS-210 (Holland Scientific, Lincoln, USA) [45-46]. Shaver et al. [46] found that NDVI calculated with red, or amber performed well to predict maize leaf N content. On wheat, one study used 590nm and obtained relevant results [45]. Samborski et al. [45] calculated amber NDVI with 590nm instead of red to prescribe variable N rates based on canopy reflectance measurements. They found a strong amber NDVI response to variable N application [45]. Thus, it is interesting to note that this work showed the value of reflectance in amber measured by remote sensing in contrast to other works studying this wavelength which were based on proximal sensing measurements. It is important to mention that most of the works studying a wide spectrum of wavelengths are done by proximal sensing to assess more wavelengths using a hyperspectral camera. However, because there are quantitative and qualitative differences between leaf and cover reflectance, leaf reflectance properties are not always directly applicable to the cover [1].

4.1.2. Difficulty in extracting an effective VI in a wide range of situations

Even if general trends emerged, it was difficult to identify a consistent and suitable wavelengths combination to predict N status for all situations. Li et al. [17] have tested different wavelengths combination to find an optimum VI to predict canopy N concentration (%N) and as in this study, the wavelengths selected varied according to the 9-dataset tested (2 different varieties, 2 years, 2 stages, 2 sites and one dataset combining all the data). For example, in their case, NDVI formulation calculated with 662nm and 674nm performed better in 2010 ($R^2_{\text{validation}}=0.61$), while in 2011 the optimum wavelengths were 302nm and 694nm ($R^2_{\text{validation}}=0.63$). Concerning VI formulation, Hansen and Schjoerring [26] highlighted that the different VI formulations were not very discriminating in predicting N status or other crops variables (biomass, LAI, chlorophyll content, etc.). They concluded that for each predicted variable the R^2 differences between the best and the worst VI ranged from 4 to 6%, which was low [26]. This is in line with the results of Li et al. [17], who highlighted that most of the traditionally used VI had a weak relationship with canopy N concentration (%N) (best $R^2=0.51$). As

demonstrated by Zheng et al. [10], making the indices more complex did not make them more relevant. For example, in this study a simple ratio (NG) reduced prediction error compared to more complex VI. According to Zheng et al. [10], Li et al. [17] and Chen [12], estimating crop N status was highly variable because VIs take into account only a limited number of wavelengths, they are very specific and depend on stage, variety, site, planting density or a year [10,17,26]. Rodriguez et al. [7] and Chen [12] also warned about the effect of cumulative stresses which are important confounding factors of N status. As discussed before in this work, among the available wavelengths it was possible to identify relevant wavelengths to predict NNI, especially at stage Z32 where the best formulation in 2020 and 2021 were made with the reflectance in 940nm and 550nm. However as demonstrated by Li et al. [17], it was not possible to find an optimum VI available between different growing stages. Concerning VI formulation, the selection according to RMSE regardless of the VI formulation highlighted the difficulty in finding the most responsive formulation, however, except for Z39 in 2020, NG formulation was one of the most selected combinations, especially in 2021. Comparing 2020 and 2021, it seemed more obvious to identify trends between the Z32 stages than at the end of vegetative growth (Z39 and Z35). Thus, predictions were more stable during elongation. In addition, the predictive capacity of optimal VI were better at this stage than at Z39 and Z45 (2020: R^2 validation=0.88 at Z32 and 0.49 at Z39, 2021: R^2 validation=0.72 at Z32 and 0.38 at Z45 for optimal VI at each stage). As parametric models only consider 2 or 3 wavelengths, studying non-parametric models are of interest for considering a wide range of spectral reflectance measured with the Kernel camera.

4.2. Evaluation of different NNI prediction models

Several studies [10,17,24] present the use of non-parametric models as a reliable technique to predict leaf N content ($\text{g}\cdot\text{m}^{-2}$) [10], leaf N concentration (%N) [24], canopy N content ($\text{g}\cdot\text{m}^{-2}$) [10], canopy N concentration (%N) [17] as they allow to consider more wavelengths than simple VI. From a such method, N status prediction should be less specific and prediction accuracy aims to increase. Zheng et al. [10], Li et al., [17] and Yao et al. [23], concluded that most of the predicted algorithms tested outperformed the optimal VI studied individually. After selecting the combinations minimizing the RMSE (per VI formulation and regardless of the VI formulation), 4 different modeling algorithms were tested: Ridge, RF, PCR and PLS models.

4.2.1. Relevant application of Ridge, PLS and PCR models on the training and validation dataset

For the performance of each prediction algorithm, the first steps of training and validation have shown that despite high training and validation R^2 the RF model was not adapted to our dataset. Indeed, RF models showed an overfitting in our situation, probably because there were insufficient individuals in the training dataset, due to RF sensitivity to outliers or by creating overly complex models [25,49]. Several other studies mentioned this problem for complex modeling algorithms with many input variables or parameters [25]. Complex algorithms, such as RF, artificial neural networks (ANN) and support vector machines (SVM) are prone to overfitting [23, 25]. The results obtained for RF models were contrary to Zheng et al. [10] who concluded on the best-performing RF among the 13 models tested in their study. In their work, R^2 reached 0.79, however only a k-fold ($k=10$) cross-validation procedure was made. The aim of modeling algorithms was to predict a variable of interest in new situations, it was therefore necessary to evaluate the performance of the model on a validation or another dataset. However, this step is not carried out in some studies and so overfitting cannot be considered [25].

In this study Ridge, PLS and PCR models performed as well as, or even slightly better than the optimal VI combinations for Z32 stages. At Z32 in 2020, the PCR and PLS with the combinations regardless of

the VI formulation were the best performing models on the training dataset ($R^2_{\text{training}}=0.4$) while the Ridge model with the best combinations per VI had the best prediction quality on validation dataset ($R^2_{\text{validation}}=0.89$). Thus, by comparing the optimal combination and non-parametric models in 2020, it was slightly better to use a non-parametric model to predict NNI than the best performing VI (GNDVI 940-550, $R^2_{\text{training}}=0.36$, $R^2_{\text{validation}}=0.88$). For the 2021 training and validation datasets, PCR and PLS models with the best combinations per VI allowed us to reach the higher R^2 ($R^2_{\text{training}}=0.53$, $R^2_{\text{validation}}=0.72$) with better results than the best VI for this stage (NG 940-550, $R^2_{\text{training}}=0.47$, $R^2_{\text{validation}}=0.72$). In this study, it appeared that the models do not significantly increase the predictive performance of the NNI. This is consistent with Yao et al. [23] who tested 4 models (Stepwise multiple regression, PLS, ANN and SVM) and observed that the models do not perform better than VI with optimum wavelength choice, even if PLS models present interesting perspectives. On the contrary, Li et al. [17] showed a relevant application of PLS models. Prediction by VIs achieved an $R^2_{\text{validation}}$ of 0.63 (NDSI with 302nm and 694nm) while the best $R^2_{\text{validation}}$ with PLS model was 0.90. Yang et al. [16] highlighted the interest of PSO-SVR models combining VI and wavelengths ($R^2_{\text{training}}=0.9$, $R^2_{\text{validation}}=0.79$) while R^2 of the linear relationship between canopy N contents ($\text{g}\cdot\text{m}^{-2}$) and VI ranged from 0.62 up to 0.73.

4.2.2. Testing models: interest of PLS and PCR models

Models made at stage Z32, which presented a relevant application, were then tested on 2021 dataset for 2020 models and vice versa. As mentioned earlier, the application of the RF model to another year's dataset confirmed that it was not sustainable applied to our dataset. The best R^2_{test} were obtained for the Ridge models, however the values produced by this model were outliers: overestimated for the 2020 model applied on 2021 data and vice versa. PCR and PLS models had average predictive performance: R^2_{test} up to 0.45 for the 2020 models tested on 2021 data. However, even if these models did not have the best prediction accuracy, they allowed consistent NNI values to be predicted contrary to the Ridge and RF models. This was consistent with Li et al. and Makowski et al. [17,25] who mentioned that these models can consider large amounts of data and are adapted to spectral reflectance data, i.e. a dataset with many correlated wavelengths and more variables than individuals.

4.2.3. Parameters influencing the predictive quality of the models

4.2.3.1. Stage effect: better results during jointing

In general, the models performed better at the Z32 stage in the two years studied while overfitting problems occurred for stages Z39 in 2020 and Z45 in 2021. These differences were more pronounced in terms of prediction error in 2020. Usually, the opposite is more common for VI; Yao et al. [23], Quemada et al. [11] and Li et al. [17] achieved better performance in the later growth stage than in earlier stages. Yao et al. [23] explained this by a reduced soil effect at later stage, while for Li et al. [17] this was due to fewer variations in canopy structure. However, a good N status monitoring at stage Z32 is interesting for application in dynamic N fertilization monitoring because N uptake increases considerably during jointing, and N requirements during vegetative growth (before flowering) are mainly related to the establishment of the yield components [47]. And after the booting stage, N fertilizer applications cannot be efficiently used by the crop [48]. Thus, being able to estimate the N status at Z32 seems to be of great interest to fulfil the objective of a more adapted dynamic fertilization.

4.2.3.2. Impact of the year

The application of the 2020 models on the 2021 dataset performed better than the 2021 models on the 2020 dataset. The worst performances were obtained with 2021 models with combinations regardless of the VI. The best R^2_{test} (0.52) was achieved using the 2020 Ridge model with the best combinations per VI applied on 2021 dataset. In general, predictions were worse on another year's

dataset than on the validation datasets. This was due in part to the model's robustness which strongly depends on the training dataset [17]. In this study, only one year was used for the training, so the models were very specific to the context of the training year. However, unlike the validation dataset, the dataset from another year contained more measurements taken under different conditions than the training dataset, which justified a lower R^2 . Li et al. [17] highlighted the use of contrasting dataset to calibrate and validate each other's conduct to decrease the prediction accuracy. Calibrating and validating models on dataset combining different years, varieties, (etc.) leads to increase predictive accuracy [17]. In this study, it was not the case if 2020 and 2021 were combined (data not shown). This can probably be explained by the fact that data comes from two contrasting years, as illustrated by the overall precipitation for example, between March and July: it was 205.8mm in 2020 while it rained 324.1mm in 2021 during the same period [50]. This was particularly the case for VIs that were not formulated as ratios such as the MCARI (Table 3). In fact, the median reflectance values in 808 and 850nm were contrasted between the two years (low in 2020 and high in 2021), so the MCARI led to high absolute predicted NNI values when the 2020 model was applied to the 2021 dataset and vice versa. Normalized difference VI formulations, like GNDVI and NDVI, reduced this problem.

4.2.3.3. *Influence of the number of inputs variables*

By comparing models made with combinations minimizing RMSE per VI or regardless of the VI formulation, the predictive capacity of models depended on the input variables. In 2020-Z32, the models with the best combinations per VI had a lower predictive capacity than models regardless of the VI formulation on the training dataset, while the opposite was observed on the validation dataset. This is consistent with Yao et al. [23] who highlighted that when the number of input variables increased, R^2 also increased on the training dataset and R^2 validation decreased. This indicates that the stability of algorithms was not good. This phenomenon is less observed in 2021. This is the case for the Ridge models but not for the PCR and PLS models. For this work it also raised the question of the optimal number of input variables for non-parametric models. In fact, when the models were tested on another year dataset, models made with the best combinations per VI allowed more consistent NNI values to be predicted. While some VI formulations (especially NDRE) were not adapted to predict NNI in our situation. However selected combination according to the RMSE regardless of the VI formulation led to training models with many input variables, which made it more complex to apply in the field. In this context, based on this work, further studies may focus on making these models more operational.

5. Conclusion

This study explored the performances and advantages of different parametric and non-parametric methods to predict winter wheat NNI, based on reflectance measurement made by UAV in 15 wavelengths. A wide range of wavelengths has been studied (from 405nm to 940nm), which made it possible to evaluate the performance of 248 VIs in predicting NNI. To date studies made by UAV are based on a limited number of wavelengths and for this type of study, proximal sensing is usually preferred.

As demonstrates in other works, we found that it was difficult to identify a consistent and suitable wavelengths combination to predict NNI in all situations, i.e. two years (2020 and 2021) and two stages per year. However, among the studied wavelengths it was possible to identify relevant wavelengths to predict NNI: 940nm (NIR), 780nm (end of the RedEdge), 632nm (beginning Red), 590nm (Amber) and 550nm (Green). While VIs combining Green and NIR seemed to be of interest for the two years studied especially at stage Z32 where the best formulations in 2020 and 2021 were made with the reflectance in 940nm and 550nm. Comparing 2020 and 2021, predictions were more stable at the beginning of elongation as the wavelengths selected were the same between the two years. In addition, the

predictive capacity of optimal VI were better at this stage than at Z39 and 45. These results were particularly interesting for a further application in dynamic N fertilization monitoring. This was because after booting stage, N fertilizer applications were not efficiently used by the crop. Studying non-parametric models was of interest for considering a wide range of spectral reflectance measured using the Kernel camera because parametric models only considered two or three wavelengths.

At stage Z32, the use of non-parametric prediction models presented interesting perspectives, as they performed equally or better compared to the best VI combination. In practice, by considering more wavelengths than simple VI, the models should be more efficient and less specific. However, testing on another year dataset, the RF and Ridge models predicted inconsistent NNI values on the other year dataset. This is why PLS and PCR models seem to be the best models to predict NNI.

In perspective, two solutions would improve the predictive capacity of the models. First, as only two contrasting data sets were used to construct and validate models, embedding more data from other years would increase the prediction accuracy. Second, when the models are tested on another year dataset, the models with a reduced number of variables (combinations per VI) seem to be more accurate than models with more explanatory variables. In this context, based on this work, further studies may focus on making more operational PCR or PLS models, using the best performing combinations individually while setting a limit of 6 wavelengths which corresponds to the number of camera lenses in our situation.

Funding: This research was funded by Agence de l'eau Artois Picardie and JUNIA

Acknowledgments: The authors would like to thank the Chambre d'Agriculture du Nord Pas de Calais for their technical support during the experiments.

Conflicts of Interest: The authors declare no conflict of interest

References

1. Knipling E.B. Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. *Remote Sensing of Environment*, **1970**, 1, pp. 155-159. doi.org/10.1016/S0034-4257(70)80021-9.
2. Kuska, M.T., Behmann J., Mahlein A.-K. Potential of hyperspectral imaging to detect and identify the impact of chemical warfare compounds on plant tissue. *Pure and Applied Chemistry*, **2018**, 90(10). doi.org/10.1515/pac-2018-0102.
3. Bao Y., Xu K., Min J., Xu J. Estimating Wheat shoot nitrogen content at vegetative stage from in situ hyperspectral measurements. *Crop Science*, **2013**, 53, pp. 2063-2071. doi.org/10.2135/cropsci2013.01.0012.
4. Padilla F.M., Gallardo M., Pena-Fleitas M.T., De Souza R., Thompson R. Proximal optical sensors for nitrogen management of vegetable crops: A Review. *Sensors*, **2018**, 2083, pp. 1-23. doi.org/10.3390/s18072083.
5. Diacono M., Rubino P., Montemurro F. Precision nitrogen management of wheat. A review. *Agron. Sustain. Dev.*, **2013**, 33, pp. 219–241. doi.org/10.1007/s13593-012-0111-z.
6. Basso B., Fiorentino C., Cammarano D. Variable rate nitrogen fertilizer response in wheat using remote sensing agriculture. *Precision Agriculture*, **2015**, 17, pp. 168-182. doi.org/10.1007/s11119-015-9414-9.
7. Rodriguez D., Fitzgerald G.J., Belford R., Chistensen L.K. Detection of nitrogen deficiency in wheat from spectral reflectance indices and basic crop eco-physiological concepts. *Australian Journal of Agricultural Research*, **2006**, 57, pp. 781–789. doi.org/10.1071/AR05361.
8. Cammarano D., Fitzgerald G.J., Casa R., Basso B. Assessing the robustness of vegetation indices to estimate wheat N in mediterranean environments. *Remote Sens.*, **2014**, 6, pp. 2827-2844. doi.org/10.3390/rs6042827.
9. Jinru X., Su B. Significant remote sensing vegetation indices: a review of developments and applications. *Journal of Sensors*, **2017**, pp. 1-17. doi.org/10.1155/2017/1353691.
10. Zheng H., Li W., Jiang J., Liu Y., Cheng T., Tian Y., Zhu Y., Cao W., Zhang Y., Yao X. A comparative assessment of different modeling algorithms for estimating leaf nitrogen content in winter wheat using multispectral images from an unmanned aerial vehicle. *Remote Sensing*, **2018**, 10, pp. 2026-2042. doi.org/10.3390/rs10122026.
11. Quemada M., Pancorbo J.L., Alonso-Ayuso M., Gabriel J.L., Lopez-Herrera J, Perez-Martin E. Vegetation indices from remote sensing imagery as proxies for yield and grain N in wheat. In: Precision Agriculture '19: Proceedings of the 12th European Conference on Precision Agriculture, edited by J.V. Stafford, BIOS Scientific Publishers Ltd, Oxford, UK, pp. 323-330
12. Chen P. A Comparison of two approaches for estimating the wheat nitrogen nutrition index using remote sensing. *Remote sensing*, **2015**, 7, pp. 4527-4548. doi.org/10.3390/rs70404527.
13. Fu Z., Jiang J., Gao Y., Krienke B., Wang M., Zhong K., Cao Q., Tian Y., Zhu Y., Cao W., Liu X. Wheat growth monitoring and yield estimation based on multi-rotor unmanned aerial vehicle. *Remote Sensing*, **2020**, 12, pp. 508-526. doi.org/10.3390/rs12030508.

14. Gordillo-Salinas V.M., Flores-Magdaleno H., Ortiz-Solorio C.A., Arteaga-Ramírez R. Evaluation of nitrogen status in a wheat crop using unmanned aerial vehicle images. *Chilean Journal of Agricultural Research*, **2021**, 81(3), pp. 408-419
15. Niu Q., Feng H., Li C., Yang G., Fu Y., Li Z., Pei H. Estimation of leaf nitrogen concentration of winter wheat using uav-based RGB imagery. *IFIP Advances in Information and Communication Technology*, **2019**, 546, pp. 139-153. doi.org/10.1007/978-3-030-06179-1_15
16. Yang B., Wang M., Sha Z., Wang B., Chen J., Yao X., Cheng T., Cao W., Zhu Y. Evaluation of aboveground nitrogen content of winter wheat using digital imagery of unmanned aerial vehicles. *Sensors*, **2019**, 19, pp. 4416-4433. doi.org/10.3390/s19204416.
17. Li F., Mistele B., Hu Y., Chen X., Schmidhalter U. Reflectance estimation of canopy nitrogen content in winter wheat using optimised hyperspectral spectral indices and partial least squares regression. *European Journal of Agronomy*, **2014**, 52, pp. 198-209. doi.org/10.1016/j.eja.2013.09.006.
18. Argento F., Anken T., Abt F., Vogelsanger E., Walter A., Liebisch F. Site-specific nitrogen management in winter wheat supported by low-altitude remote sensing and soil data. *Precision Agriculture*, **2020**, 22, pp. 364-386. doi.org/10.1007/s11119-020-09733-3.
19. Justes, E., Mary, B., Meynard J-M., Machet J-M., Huché-Théliet L. Determination of a critical nitrogen dilution curve for winter wheat crops. *Annals of Botany*, **1994**, 74, pp. 397-407.
20. Lemaire G. Une nouvelle approche de la fertilization des cultures. *Agronomie, Environnement & Sociétés, Association Française d'Agronomie (Afa)*, **2019**, 9.
21. Gastal F., Lemaire G., Durand J.L., Louarn G. Quantifying crop responses to nitrogen and avenues to improve nitrogen-use efficiency. *Crop Physiology*, **2015**, Chap. 8, pp. 161-206. doi.org/10.1016/B978-0-12-417104-6.00008-X.
22. Lemaire G., Ciampitti I. Crop mass and n status as prerequisite covariables for unraveling nitrogen use efficiency across genotype-by-environment-by-management scenarios: A Review. *Plants*, **2020**, 9, pp. 1309-1327. doi.org/10.3390/plants9101309.
23. Yao X., Huang Y., Shang G., Zhou C., Cheng T., Tian Y., Cao W., Zhu Y. Evaluation of six algorithms to monitor wheat leaf nitrogen concentration. *Remote Sens.*, **2015**, 7, pp. 14939-14966. doi.org/10.3390/rs71114939.
24. Liu Y., Cheng T., Zhu Y., Tian Y., Cao W., Yao X., Wang N. Comparative analysis of vegetation indices, non-parametric and physical retrieval methods for monitoring nitrogen in wheat using UAV-based multispectral imagery. In : International Geoscience and Remote Sensing Symposium (IGARSS), 2016, pp. 7362-7365
25. Makowski D., Brun F., Doutart E., Duyme F., El Jabri M., Fauvel K., Legris M., Philibert A., Piroux F., Ternier A. Data science pour l'agriculture et l'environnement. Ellipses: Paris, **2021**.
26. Hansen P.M., Schjoerring J.K. Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. *Remote Sensing of Environment*, **2003**, 86, pp. 542-553. doi.org/10.1016/S0034-4257(03)00131-7.
27. COMIFER, 2013. Calcul de la fertilization azotée. Guide méthodologique pour l'établissement des prescriptions locales. Cultures annuelles et prairies. Available online:

- http://www.comifer.asso.fr/images/publications/brochures/BROCHURE_AZOTE_20130705_web.pdf (accessed on 08/04/2021)
28. Zadoks J.C., Chang T., Konzak C.F. A decimal code for the growth stages of cereals. *Weed Research*, **1974**, 14, pp. 415-421
 29. Kuhn, M. 2008. Building predictive models in R using the caret Package. *Journal of Statistical Software*, 28(5), 1 - 26. doi.org/10.18637/jss.v028.i05.
 30. Rouse J.W., Haas R.H., Schell J.A., Deering D.W. Monitoring vegetation systems in the great plains with ERTS. ERTS symposium, NASA, **1973**, SP-351, Washington DC 1 309-317
 31. Buschmann C., Nagel E. In vivo spectroscopy and internal optics of leaves as basis for remote sensing of vegetation. *International Journal of Remote Sensing*, **1993**, 14, pp. 711–722. doi.org/10.1080/01431169308904370.
 32. Haboudane D., Tremblay N., Miller J.R. Remote estimation of crop chlorophyll content using spectral indices derived from hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, **2008**, 46(2), pp. 423-437. doi.org/10.1109/TGRS.2007.904836.
 33. Barnes E.M., Clarke T.R., Richards S.E., Colaizzi P.D., Haberland J., Kostrzewski M., Waller P., Choi C., Riley E., Thompson T., Lascano R.J., Li H., Moran M.S. Coincident detection of crop water stress, nitrogen status and canopy density using ground-based multispectral data. Proceedings of the Fifth International Conference on Precision Agriculture, **2000**, ASA, Madison, WI.
 34. Rondeaux G., Steven M., Baret F. Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*, **1996**, 55, pp. 95-107
 35. Sripada, R., Heiniger, R., White, J. & Meijer, A. Aerial colorinfrared photography for determining early in-season nitrogen requirements in corn. *Agronomy Journal*, **2006**, 98, pp. 968–977. doi.org/10.2134/agronj2005.0200
 36. Mevik B.-H., Wehrens R. and Hovde Liland K. **2020**. pls: Partial Least Squares and Principal Component Regression. R package version 2.7-3. Available online: <https://CRAN.R-project.org/package=pls> (accessed on 18/12/2021)
 37. Friedman J., Hastie T., Tibshirani R. **2010**. Regularization paths for generalized linear models via coordinate descent. *Journal of Statistical Software*, 33(1), pp. 1-22. Available online: <https://www.jstatsoft.org/v33/i01/> (accessed on 18/12/2021)
 38. Liaw, A. and Wiener, M. Classification and regression by Random Forest. *R News*, **2002**, 2, pp. 18-22
 39. Brun F., Makowski D., Wallach D. and Jones J.W. **2018**. ZeBook: Working with dynamic models for agriculture and environment. R package version 1.1. Available online: <https://CRAN.R-project.org/package=ZeBook> (accessed on 18/12/2021)
 40. Colaço A.F., Bramley R.G.V. Do crop sensors promote improved nitrogen management in grain crops? *Field Crops Research*, **2018**, 218, pp. 126-140. doi.org/10.1016/j.fcr.2018.01.007.
 41. Lemaire G., Jeuffroy M.H., Gastal F. Diagnosis tool for plant and crop N status in vegetative stage theory and practices for crop N management. *European Journal of Agronomy*, **2008**, 28, pp. 614–624. doi.org/10.1016/j.eja.2008.01.005.

42. Cartelat A., Cerovic Z. G., Goulas Y., Meyer S., Lelarge C., Prioul J. L. Optically assessed contents of leaf polyphenolics and chlorophyll as indicators of nitrogen deficiency in wheat (*Triticum aestivum* L.). *Field Crops Research*, **2005**, 91, pp. 35–49. doi.org/10.1016/j.fcr.2004.05.002.
43. Hatfield J.L., Gitelson A.A., Schepers J.S., Walthall C.L. Application of spectral remote sensing for agronomic decisions. *Agronomy Journal*, **2008**, 100(3), pp. 117-131. doi.org/10.2134/agronj2006.0370c.
44. Gabriel J.L., Zarco-Tejada P.J., Lopez-Herrera P.J., Perez-Martin E., Alonso-Ayuso M., Quemada M. Airborne and ground level sensors for monitoring nitrogen status in a maize crop. *Biosystems Engineering*, **2017**, 160, 124-133. doi.org/10.1016/j.biosystemseng.2017.06.003.
45. Samborski S.M., Stępień M., Walsh O. On-farm evaluation of an active optical sensor performance for variable nitrogen application in winter wheat. *European Journal of Agronomy*, **2015**, 74, pp. 56-67. doi.org/10.1016/j.eja.2015.11.020.
46. Shaver T.M., Khosla R., WestfallCao D.G. Evaluation of two crop canopy sensors for nitrogen variability determination in irrigated maize. *Precision Agriculture*, **2011**, 12(6), pp. 892-904. doi.org/10.1007/s11119-011-9229-2.
47. Orloff S., Wright S., Ottman M. Nitrogen management impacts on wheat yield and protein. In : Proceedings of California Alfalfa & Grains Symposium, 2012, Sacramento, CA, December
48. Ravier C., Sabatier R., Beillouin D., Meynard J.M., Trépos R., Jeuffroy M.H. Decision rules for managing N fertilization based on model simulations and viability assessment. *European Journal of Agronomy*, **2021**, 125. doi.org/10.1016/j.eja.2021.126247
49. Belgiu M., Dragut L. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2016, 114, pp. 24–31. doi.org/10.1016/j.isprsjprs.2016.01.011.
50. Meteociel, Données mensuelles pour Lille. 2021. Available online: https://www.meteociel.fr/climatologie/obs_villes.php?code=7015&mois=12&annee=2021 (accessed on 08/01/2022)
51. Berger K., Verrelst J., Féret J.B., Wang Z., Woche M., Strathmann M., Danner M., Mauser W., Hank T. Crop nitrogen monitoring: Recent progress and principal developments in the context of imaging spectroscopy missions. *Remote Sensing of Environment*, **2020**, 242. doi.org/10.1016/j.rse.2020.111758.

Chapitre III

Création d'un modèle prédictif de l'INN basé sur des mesures non-destructives du statut azoté par proxi- et télédétection en vue d'un pilotage dynamique et spatialisé de la fertilisation azotée

Plusieurs études ont montré des résultats concluants concernant le potentiel de prédiction du statut azoté des cultures par des modèles de régressions non-paramétriques prenant en compte plusieurs indices de végétation (IV) ou IV et longueurs d'onde (Zheng et al., 2018; Yang et al., 2019; Li et al., 2014; Yao et al., 2015, Fu et al., 2020). Ceux-ci permettent de dépasser les limites des modèles paramétriques basés sur un seul IV pour prédire le statut azoté, i.e. une prise en compte partielle des informations mesurées (formulation avec 2-3 longueurs d'onde seulement), le manque de spécificité des IV au statut azoté (la prise en considération d'une petite portion du spectre ne permet pas d'isoler une variable agissant sur la réflectance du couvert, des confusions sont possibles avec la réflectance du sol, le LAI, la structure du couvert, etc.), une sensibilité forte aux conditions de mesures rendant difficile l'extrapolation à d'autres situations (Berger et al., 2020 ; Atzberger et al., 2011). Cependant, malgré les bonnes performances des modèles non-paramétriques mises en avant dans la littérature, ils sont souvent complexes et manquent de validation, ce qui les rend peu opérationnels. Le **chapitre 2** a permis d'évaluer la capacité de prédiction du statut azoté de 4 modèles différents. Dans notre contexte, le modèle PLS semble pertinent : il permet de prédire des valeurs d'INN (indice de nutrition azotée) cohérentes avec une qualité de prédiction satisfaisante.

Les variables d'entrées avaient été sélectionnées de 2 façons différentes parmi 248 combinaisons de longueurs d'onde calculées. À la suite de l'évaluation individuelle de ces combinaisons, une première sélection a été faite, choisissant la combinaison minimisant l'erreur de prédiction par formulation d'IV. D'un point de vue pratique, cette première méthode n'est pas forcément appropriée étant donné que les IV ne sont pas tous pertinents pour prédire le statut azoté. La seconde méthode de sélection s'est basée sur les combinaisons minimisant l'erreur de prédiction (seuil) quelle que soit la formulation de l'IV. Celle-ci a conduit à des modèles avec un nombre de variables d'entrées conséquents. Dans la pratique, mesurer toutes les réflectances retenues dans les modèles nécessite plusieurs vols, rendant le temps d'acquisition très long. Ainsi, ce constat met en évidence le besoin de bénéficier de modèles opérationnels pour prédire le statut azoté en cours de croissance.

Afin de rendre ce suivi plus opérationnel, tout en permettant une estimation précise et spatialisée de l'INN, ce **chapitre 3** sera divisé en 2 volets. Dans un premier temps, dans la continuité du chapitre précédent, les résultats d'un travail de recherche sur la création de modèles de prédiction du statut azoté seront présentés. L'objectif étant que les modèles soient opérationnels dans le cadre d'une démarche de pilotage dynamique de la fertilisation utilisant la culture comme indicateur. Le principe général est de se baser sur le potentiel des modèles PLS tout en limitant le nombre d'IV utilisés comme variables d'entrée de façon à opérationnaliser le modèle en ne prenant en compte qu'un nombre limité de longueurs d'onde. Etant donné que la qualité de prédiction des modèles était meilleure au stade 2 nœuds, ce chapitre se concentrera sur ce stade. Ce dernier arrivant tôt en saison, il est en outre plus pertinent dans le cadre d'une application à un modèle de pilotage dynamique. Dans un second temps, en parallèle des mesures prises par télédétection, ce **chapitre 3** s'intéressera également aux mesures du statut azoté par proxidtection via l'utilisation d'un capteur optique foliaire (Dualex, Force A, Orsay, France). Celui-ci se base sur le contenu en pigments des feuilles, mesuré par transmittance et fluorescence, pour estimer le statut azoté et a pour avantage d'être très précis et peu impacté par l'effet du sol et des conditions de mesures. Toutefois, son application et la représentativité des mesures sont limitées sur une grande surface (Muñoz-Huerta et al., 2013, Berger et al., 2020).

Ainsi, après avoir évalué le potentiel de prédiction du statut azoté par un capteur optique foliaire (Dualex, Force A, Orsay, France), une dernière partie de ce chapitre portera sur l'exploration de modèles PLS combinant des mesures prises par proxi- et télédétection. Cette combinaison devrait permettre d'associer les avantages de ces 2 échelles de mesure, à savoir la précision des mesures prises

par proxidtection et la prise en compte de la variabilité spatiale des besoins en N grâce à la télédtection.

Ce chapitre présente les résultats obtenus sur les données collectées dans des essais présentant un gradient de fertilisation azotée, en 2020 à Savy (62) et Fréwillers (62) en 2021 pour les parties prox- et télédtection, ainsi que les données acquises en 2019 à Houvin (62) par proxidtection.

Non-destructive prediction of NNI by proximal and remote sensing for dynamic and spatialized fertilization management

Bouchard Marie-Astrid ^{1*}, Vandoorne Bertrand¹ and Andriamandroso A.L.Herinaina ¹

¹Université de Liège, Junia, UMRT 1158 BioEcoAgro - Conduction, optimization and design of cropping systems meeting multi-criteria objectives, B-5030 Gembloux, Belgique

*Correspondence: marie-astrid.bouchard@junia.com

Abstract :

To increase Nitrogen (N) use efficiency (NUE), assessing N status in real time is important to adapt the N fertilizer rate by applying the right amount, at the right time and in the right place to match crops' demand and avoid environmental losses. In this context, proximal and remote sensing offers good opportunities. After evaluating the N nutrition index (NNI) predictive capacity by proximal sensing, the objectives of this study were: (i) to evaluate the performance of an operational partial least squares (PLS) model made with optimal vegetation indices (VI) to predict NNI, optimal VI were selected among 248 calculated combinations, and (ii) to test if the combination of proximal and remote sensing measurement increase NNI prediction accuracy. During three growing seasons (2019 to 2021) three fields showing various patterns of NNI dynamics were monitored in the North of France. In a first time, the Dualex leaf-clip (Force A, Orsay, France) presents a relevant application to predict NNI ($R^2=0.78$). Secondly, PLS models were created with the best combinations per year by limiting the number of wavelengths used to 6, which corresponds to the number of camera lenses. These achieve similar results as the best combinations considered in the model. Finally, non-parametric models offer the opportunity to combine the benefits of proximal and remote sensing. This study confirms the interest of this combination, which allow to take advantages of these 2 measurements scale: proximal sensing accuracy and spatial heterogeneity consideration by remote sensing. The results from this study could be applied for dynamic fertilisation management and further work will focus on the practical implementation in farmer fields, especially by defining how many proximal measurement points are necessary in addition to remote sensing measurements.

1. Introduction

Nitrogen (N) is one of the essential nutrients for wheat growth and a sufficient uptake is required to maintain high yield and quality at harvest (Bao et al., 2013). Because N remains a limiting factor for the growth of most plants (Hawkesford et al., 2012; Gastal et al., 2015) global use of N fertilisers has increased dramatically since the 1950s (Vance, 2001), with a worldwide N consumption for agricultural use reaching 108MT (FAO, 2019). However cereal N use efficiency (NUE) was estimated at 35% for the world (Omara et al., 2019). NUE correspond to the increase in yield per unit of N available for crop (Moll et al., 1982), is it defined as the product of N uptake and utilization efficiency (Cohan et al., 2018). Thus, this low NUE highlights that, to ensure productivity, N fertilizers are often applied in excess to the crops N requirements (Omara et al., 2019). While the N surplus may be lost within soil through leaching and/or gaseous forms leading to N pollution (Omara et al., 2019; Sharma and Bali, 2018). In this context, the issue is therefore to increase the NUE to minimize the N pollution while maintaining high crop yield and satisfactory quality at harvest (Masclaux-Daubresse et al., 2010; Sharma et Bali, 2018). In this purpose, because crop N requirement varies in space and time, assessing N status in real time is important to adapt the N fertilizer rate by applying the right amount, at the right time, in the right place and match crops' needs.

The N nutrition index (NNI) is recognised as a relevant N status indicator during the growing season (Lemaire, 2019; Gastal et al., 2015; Lemaire et Ciampitti, 2020), and Ravier et al. (2017) showed that estimating NNI is interesting in order to manage fertilisation. NNI is defined by Justes et al. (1994) as the ratio between measured N concentration (%N) and the critical N concentration (%N_c) for a defined dry biomass (DM), with %N_c corresponding to the minimum N concentration necessary to achieve the optimal growth. Thus, NNI monitoring makes it possible to follow the dynamics of N in the canopy and, by comparison with a reference, to identify N deficiencies that suggest a yield decrease (Aranguren et al., 2020).

Measuring NNI will require a destructive (sampling), time-consuming and costly method that is not compatible with the use of NNI in field crop monitoring (Quemada et al., 2019, Aranguren et al., 2020). To become more efficient, indirect estimation of NNI, by proximal or remote sensing optical measurement, therefore seems promising (Lemaire et al., 2008; Lemaire, 2019; Bouchard et al., 2021).

Proximal sensing includes measurements taken at leaf level (based on pigment content measured by absorbance, transmittance and fluorescence) and canopy reflectance measurements made close to the cover by ground-based sensors. Jiang et al. (2021), have compared 2 leaf sensors (SPAD 502 and Dualex 4 Scientific+) and one canopy sensor (RapidSCAN CS-45). As demonstrate in other studies (Quemada et al., 2019; Aranguren et al., 2020) they concluded that proximal sensor-based measurements are appropriate to diagnose the winter wheat N status. Even if estimations are easily influenced by crop growth stage, Jiang et al. (2021) obtained coefficient of determination (R^2) for linear regression between leaf N content and sensor-based indices ranged from 0.54 to 0.71 for SPAD, 0.66 to 0.84 for Dualex and 0.72 to 0.86 for RapidSCAN indices. As the measurements are made at leaf scale, they are not influenced by the atmospheric conditions and the soil effect, which makes it possible to obtain very good correlations between the measurements taken by these tools and the crop parameters with high accuracy (Muñoz-Huerta et al., 2013). Proximal sensing has the advantages to be easy to use as well as being affordable. However, these tools are limited in terms of measurement area, as they poorly consider the spatial variability (Muñoz-Huerta et al., 2013). Such sensors also make measurements in a limited number of wavelengths and calculated few indices, that's why these tools don't performed during the entire crop cycle (Fu et al., 2020). Finally, pigments meters are more sensitive to saturation and fail to detect overfertilized plants (Muñoz-Huerta et al., 2013).

Rapid and accurate estimation of N status has become a major issue for N fertilisation management, however due to N requirement spatial variability, proximal sensing present some limits to answer this challenge. On another scale, remote sensing has the advantages of being fast, non-destructive, repeatable, accurate and consider spatial variability (Chen, 2015). Most of the remote sensing data are obtained from camera embedded on satellite, airborne or unmanned aerial vehicles (UAV). Thanks to its flexibility of use and its spatial, spectral and temporal resolution, UAV seems suitable for estimating the crops N requirement in real-time for fertiliser management (Zheng et al., 2018; Quemada et al., 2019). Based on variations in canopy reflectance according to crops status, a range of vegetation indices (VI) have so far been proposed to predict wheat growth and its N status. Several studies have made parametric correlations between UAV-based VI with: leaf N content (g.m^{-2}) (Zheng et al., 2018), leaf N concentration (%N per dry biomass) (Niu et al., 2019), canopy N content (g.m^{-2}) (Quemada et al., 2019 ; Zheng et al., 2018 ; Yang et al., 2019; Argento et al., 2020), canopy N concentration (%N per dry biomass) (Quemada et al., 2019; Gordillo-Salinas et al., 2021; Li et al., 2014), NNI (Argento et al., 2020 ; Chen, 2015 ; Gordillo-Salinas et al., 2021) or biomass (Quemada et al., 2019 ; Chen, 2015 ; Fu et al., 2020 ; Gordillo-Salinas et al., 2021). These indices have the advantage of being operational and easy to calculate (Yao et al., 2015). However, the use of VI have some drawbacks: VI performances are dependent on the measurement conditions (site, cultivars, growth stage, years) (Zheng et al., 2018; Chen, 2015) and are impacted by the simultaneous occurrence of stress (Rodriguez et al., 2006). The strong dependence of the VIs on external elements (atmosphere, soil) and the use of a small portion of the spectrum in VI formulation highlight the difficulty to have a unified indices to predict N status in a large range of situation (Li et al., 2014). To overcome these problems, several studies have worked on the predictive capacity of non-parametric regressions considering multivariable input (Zheng et al., 2018; Yang et al., 2019; Li et al., 2014; Yao et al., 2015; Fu et al., 2020). From such methods, predictions aim to be less specific as a wider range of wavelengths can be considered. Several studies conclude that most of the predicted algorithms tested outperformed the optimal VI studied individually (Zheng et al., 2018; Li et al., 2014; Yao et al., 2015). Among non-parametric models, partial least squares (PLS) regression seems suitable for remote sensing data as it allows to reduce the large number of measured collinear spectral variables to a few non-correlated latent variables (Yao et al., 2015; Bouchard et al., unpublished). Moreover, PLS are adapted for dataset where the number of samples is fewer than the number of variables which is often the case for remote sensing data (Yao et al., 2015; Makowski et al., 2021).

To date only a few parts of the studies are focused on UAV-based NNI monitoring (Zheng, 2018; Chen, 2015; Bouchard et al., unpublished). However, NNI is a relevant indicator to monitor N status: it is specific, sensitive and allow to compare different crops' N status independently of differences in crop biomass (Lemaire et al., 2008; Colaço et al., 2018). Moreover, because non-parametric algorithms can consider many variables, most of the studies are made by proximal sensing using hyperspectral cameras to explore a large part of the spectrum (Hansen and Schjoerring, 2003; Yao et al., 2015; Li et al., 2014; Tremblay et al., 2011, Berger et al., 2020). Thus, even if these studies are scientifically relevant in practice, the models created are not very operational. Indeed, proximal tools poorly consider the spatial variability. On the contrary, studies made by UAV consider only few wavelengths (3 wI and 11 VI for Yang et al., 2019; 6wI and 9 VI for Fu et al., 2020) while the models have the capacity to exploit many variables. After evaluating the NNI predictive capacity by proximal sensing (i), the objectives of this study were: (ii) to evaluate the performance of an operational PLS model made with optimal VI (selected out of 248 combinations) to predict NNI, and (iii) to test if the combination of proximal and remote sensing measurement increase NNI prediction accuracy. By combining leaf-sensor and UAV-based measurement we aim to take advantages of these 2 measurements scale: proximal sensing accuracy and spatial heterogeneity consideration by remote sensing.

2. Materials et methods

2.1. Experimental sites and fertilisation rates

The study was carried out on winter wheat in the North of France (Pas-de-Calais region, 62) during 3 growing seasons (2018-2019 to 2020-2021). Three wheat crop experiments showing various patterns of NNI dynamics were monitored, representing different combinations of total N fertiliser levels and splitting strategies. In each site, the experiment was conducted in a randomized block design comprising 13 treatments and four replicates in 2019, 13 treatments and six replicates in 2020 and 20 treatments and four replicates in 2021 (Table 1 and 2). In 2019, trial zone represents 52 microplots of 22.5m², in 2020 78 microplots of 27.5 m², and in 2021 80 microplots of 26.3 m², implemented in a homogeneous area of a field of 7.9 ha, 11.2 ha and 5.8 ha respectively. Each treatment represented a fertilization strategy. Fertilization strategies were compared with two control treatments: an unfertilized control and the Reference Rate (R) calculated according to the balance sheet method (Comifer et al., 2013). For the 2019 experiment, wheat was sown on October 17th (2018) with Costello variety (KWS Momont, 2015, France). For the 2020 season, the Chevignon variety (Saaten Union, 2017, France) was sown on October 24th (2019). And in 2021 experiment, a varietal mixed was sown on October 20th (2020). The varietal mixed included Chevignon (Saaten Union, 2017, France), KWS Extase (KWS Momont, 2018, France) and Winner (Florimond Desprez, 2018, France) varieties, in proportions of one third of each. N applications were made with 27% ammonium nitrate.

Table 1 : Site location, previous crop and fertilizer rates at Houvin (2019), Savy (2020) and Frevillers (2021) experimental sites

Crop season-Trial	Location, degrees	Previous crop	Fertilisation gradient (kg N.ha⁻¹)	Reference rate (RR)* (kg N.ha⁻¹)
2019-Houvin	50.308324, 2.385824	Rapeseed	0-290	210
2020-Savy	50.343387, 2.550636	Rapeseed	0-315	180
2021-Frevillers	50.394806, 2.535694	Sugar beet	0-300	130

*Calculated according to the balance sheet method (Comifer, 2013)

Table 2 : Fertilisation strategies: N fertiliser rates in kg N.ha⁻¹, reported per Zadoks growth scale in 2019 (a), 2020 (b) and 2021 (c) (Zadoks et al., 1974). The bold line corresponds to the reference dose calculated according to the balance sheet method (Comifer, 2013)

(a) Input	Z29	Z31	Z32	Z39	Z51	(b) Input	Z29	Z31	Z32	Z39	(c) Input	Z21	Z29	Z31	Z32	Z39	Z59
Control	0	0	0	0	0	Control	0	0	0	0	Control	0	0	0	0	0	0
RR-80	40	50	40			RR-80	20	60	20		RR-80	20		10		20	
RR-40	40	90	40			RR-40	40	60	40		RR-40	40		30		20	
(RR)	40	130	40			(RR)	40	100	40		(RR)	40		50		40	
RR+40	40	110	40	60		RR+40	40	100	40	40	RR+40	40		50	40	40	
RR+80	60	130	40	60		RR+80	60	100	40	60	RR+80	60		50	40	60	
2019_1	40	130				2020_1	60	60	60		2021_1	40		50		40	
2019_2	40	130	80			2020_2	80	40	60		2021_2	20	40	30		40	
2019_3	80	90	120			2020_3	30	30	30		2021_3	80		50			
2019_4	150	60				2020_4	105	105	105		2021_4	80		30		20	
2019_5	150	40	20			2020_5	80	100			2021_5			70		60	
2019_6	40	90	40	40		2020_6	80	40	60		2021_6	40+30S		50		40	
2019_7	40	130	40			2020_7	40	100	40		2021_7	40+40P		50		40	
											2021_8	40		50		40	
											2021_9	40		30		40	20
											2021_10	40		30		40	20
											2021_11	30		30		30	
											2021_12	60		60		60	
											2021_13	80		80		80	
											2021_14	100		100		100	

S:Sulfur and P:Phosphorus

Normal rainfall (1981-2010) over the study area averages 743mm per year, but the 2 first years studied (2019-2020) have been deficient in rainfall with up to 15% less rainfall in 2020. While in 2021 rainfall was above normal. During the wheat fertilisation period (March to June), these differences reached -24% in 2020 and +4% in 2021. Differences in rainfall are particularly pronounced between May 2020 and 2021 (Table 3).

Table 3 : Monthly rainfalls (mm) for Lille-Lesquin weather station in 2019, 2020, 2021 and between 1981 to 2010 (MeteoFrance)

	Jan.	Feb.	March	April	May	June	July	August	Sept.	Oct.	Nov.	Dec.
2019	39.3	34.4	80.7	35	25.3	78.8	26.6	36.5	52.8	90.7	56.9	78.4
2020	29.5	92.3	63.3	41.1	4.2	72.2	25	64.1	7.6	109	37.1	83.3
2021	114.5	35.8	32.2	25.9	78.2	109.8	78	76.5	36.8	101.5	62.6	46
Normals*	60.5	47.4	58.3	50.7	64	64.6	68.5	62.8	61.6	66.2	70.1	67.8

*normals calculated from 1981 to 2010

At harvest, yield ranged from 7.49 Mg.ha⁻¹ (Control) to 12.68 Mg.ha⁻¹ (R+40) in 2019, from 5.17 Mg.ha⁻¹ (Control) to 9.58 Mg.ha⁻¹ (2020_2) in 2020 and from 3.28 Mg.ha⁻¹ (Control) to 8.91 Mg.ha⁻¹ (2021_4) in 2021. Mixed analysis of variance (ANOVA) with Tukey's multiple comparison procedure was performed to evaluate the influence of fertilisation at harvest. A p-value of 0.05 was applied to differentiate the means of the N treatments and fertilisation had a significant effect for the 3 years of

study ($p < 0.001$ in 2019 and 2020 and $p = 0.0037$ in 2021). All measurements presented in this study were taken at Zadoks growth stages Z32 (second node detectable).

2.2. Crop analysis and ground level measurements

To find a correlation between crop N status, proximal and remote sensing measurements, the N concentration (%N) was measured on the aerial part chemically. Sampling was made at stage two nodes (Z32), from late April to early May depending on the year. Biomass samples were collected on a surface of 0.25m² per microplot in 2019, and in a row of 50 cm in each plot in 2020 and 2021. Samples were then dried at 65°C in an oven to obtain the dry biomass. The dry biomass per unit area was calculated using the number of plants counted on 1 m² area in 2020 and 2021. After the samples had been finely ground, the N concentration was measured on the aerial part chemically (Dumas method, NF EN ISO 16634-1). Finally, NNI was calculated using (Eq. 1) as the ratio of measured N concentration (%N) and the critical N concentration (%N_c) for a defined dry biomass (DM). For winter wheat, N_c is obtained using (Eq. 2) (Justes et al., 1994).

$$\text{NNI} = \%N / \%N_c, \quad (\text{Eq. 1})$$

$$\text{for } DM < 1.55 \text{ T} \cdot \text{ha}^{-1} \%N_c = 4.4, \text{ for } DM > 1.5 \text{ T} \cdot \text{ha}^{-1} \%N_c = 5.35 DM^{-0.442}, \quad (\text{Eq. 2})$$

2.3. Proximal sensing measurements

For the 3 years studied, at each sampling stage (Z32), non-destructive measurements of the crop N status were taken using a Dualex 4 Scientific sensor (Force A, Orsay, France). The Dualex assesses the chlorophyll and flavonoids content according to measurement in ultra-violet (UV) and visible light. Estimation of chlorophyll content is based on transmittance at 710nm and 850nm, while flavonoids content is estimated by comparing chlorophyll fluorescence emitted under excitation at 650nm and UV (375nm) (Cerovic et al., 2012; Muñoz-Huerta et al., 2013; Padilla et al., 2018). Measurements were always done with the adaxial leaf side facing the light sources. Using this tool, a nitrogen balance index (NBI) ratio is calculated - i.e. the ratio between chlorophyll and flavonoids content - as an indicator of crop N status. For each microplot, the mean NBI was obtained from the average of 12 individual youngest fully developed leaf measurements.

2.4. Remote sensing measurements

Remote sensing measurements were made only for 2 years, in 2020 and 2021, as close as possible to ground level sampling. The UAV images were acquired with a six-lens multispectral modular camera (Kernel camera, Mapir, San Diego, CA, USA) mounted on M1Agri UAV (ADT drones, Soissons, France) (Figure 1). The modular camera used enabling to change the filters among 15 wavelengths: 405nm (±50nm), 450nm (±50nm), 490nm (±75nm), 518nm (±50nm), 550nm (±50nm), 590nm (±50nm), 615nm (±75nm), 632nm (±50nm), 650nm (±50nm), 685nm (±50nm), 725nm (±50nm), 780nm (±50nm), 808nm (±50nm), 850nm (±100nm), 940nm (±200nm). UAV flights were made at a height of 30m in favourable conditions with 75% recovery. Using the six lenses, three flights per stage are re-quired to obtain images in 15 wavelengths.




Figure 1 : Pictures of M1Agri UAV, the Kernel camera (dismantled to change the filters) and the Mapir calibration target

Calibration was made through the Mapir Camera Control software and Mapir calibration target. After calibration, the images were then processed using Pix4D software (Pix4D S.A., Prilly, Switzerland) to generate orthomosaic map in each wavelength studied. The reflectance maps for each wavelength were then processed in QGIS (QGIS Development Team 2021, version 3.10) to extract the median reflectance per microplot. The median value was used instead of the mean in order to consider vegetation reflectance and reduce the soil effect. The data exported from QGIS were analysed in RStudio (RStudio Team 2019, version 3.6.2).

2.5. Data analysis

2.5.1. Proximal sensing

Initially, mixed analysis of variance (ANOVA) with Tukey's multiple comparison procedure was performed stage by stage to evaluate the influence of fertilisation on NNI and NBI. The goal was to test the following hypothesis: (H0) there are no differences between the treatments. A p-value of 0.05 was applied to differentiate the means of the N treatments. In a second time, the predictive capacity of Dualex was assessed by studied linear relationship between NNI and NBI and evaluated using coefficient of determination (R^2), calculated with (Eq. 3). With n is the number of observations in the dataset, y_i the measured values, \bar{y} the means, and \hat{y}_i the predicted values.

$$R^2 = 1 - \left[\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \right] \quad (\text{Eq. 3})$$

Table 4 : Calculated combinations and wavelengths used according to the IV formulation (R: Red, G: Green, NIR: Near Infrared, RE: RedEdge)

				Wavelengths (nm)										
VI	Formulation	Reference	550	590	615	632	650	685	725	780	808	850	940	
NDVI	Normalized Difference Vegetation Index	$(NIR-R)/(NIR+R)$				R	R	R	R+NIR	NIR	NIR	NIR	NIR	
GNDVI	Green Normalized Difference Vegetation Index	$(NIR-G)/(NIR+G)$	G	G	±G				NIR	NIR	NIR	NIR	NIR	
MCARI	Modified Chlorophyll Absorption Reflectance Index	$[(NIR-R)-0.2 \times (NIR-G)] \times (RE/R)$	G	G		R	R	R	R+NIR	NIR	NIR	NIR	NIR	
NDRE	Normalized Difference Red Edge	$(NIR-RE)/(NIR+RE)$							RE	RE	NIR	NIR	NIR	
OSAVI	Optimized Soil Adjusted Vegetation Index	$(NIR-R)(NIR+R+0.16)(NIR-R)/(NIR+R+0.16)$				R	R	R	R+NIR	NIR	NIR	NIR	NIR	
TCARI	Transformed Chlorophyll Absorption in Reflectance Index	$3 \times [(RE-R)-0.2 \times (RE-G)] \times (RE/R)$	G	G	R	R	R	R+RE	RE	RE				
NG (GRVI)*		NIR/G	G	G	±G				NIR	NIR	NIR	NIR	NIR	
TCARI/OSAVI			G	G	R	R	R	R+RE	RE	RE	NIR	NIR	NIR	

*Different formulas according to the studies

2.5.2. Remote sensing

For UAV-based measurements, different wavelength combinations were calculated using the formulation of eight VI. The eight indices were chosen as having varying levels of complexity and use different wavelengths. With the 15 available wavelengths, a total of 248 combinations were calculated per year (Table 4). The data set for 2020 and 2021 were divided by stage using caret package (Kuhn, 2008): 75% of the data were randomly selected as the modelling data set, while the remaining 25% were used for validation

2.5.2.1. NNI estimation by parametric modelling algorithms

To set aside combinations with little interest and identify the best performing combinations, simple linear regression between NNI and all combinations were made one by one. Combinations of interest were selected according to RMSE (Eq. 4). The number of combinations minimising the prediction error was fixed by limiting the number of wavelengths used to 6. This choice is motivated by the number of lenses in the camera.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (\text{Eq. 4})$$

2.5.2.2. NNI estimation by non-parametric modelling algorithms

In a second stage, the pls package (Mevik et al., 2020) was used to build PLS (Partial Least Squares) regressions: on the one hand with the previously selected combinations, and on the other hand by integrating in addition the NBI. Models training was done on 75% of the data sets after partitioning to adjust the model parameters. To avoid overfitting, the number of components has been chosen to limit prediction error by minimizing the Predicted Residual Sum of Squares (PRESS).

The performances of the models previously created were validated firstly in terms of RMSE (Eq. 4), bias (Eq. 5) and determination coefficient (R^2 , Eq. 3) using the ZeBook package (Brun et al., 2018) with Leave-One-Out Cross-Validation.

$$\text{Bias} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i) \quad (\text{Eq. 5})$$

After training on the training dataset, the models were validated using the validation dataset. The predictive capability was assessed using the determination coefficient (R^2). Then, the model was tested on an independent dataset, i.e. on the 2021 dataset for the 2020 models and vice versa to use an independent dataset.

3. Results

3.1. Correlation between NNI and NBI

For the 3 years studied, NNI and NBI were both affected by fertilizer rates at stage Z32 ($p < 0.0001$). NNI obtained in 2020 and 2021 were close and ranged on average from 0.415 (Control) to 0.996 (2020_4) in 2020 and from 0.469 (Control) to 0.991(2021_3). In 2019, NNI levels were high this year (up to 1.688), which resulted in higher NBI levels (Figure 2).

The study of the linear relationship between NBI and NNI year by year highlighted the good ability of the NBI to predict NNI (Figure 2). Indeed, R^2 ranged from 0.53 in 2021 to 0.74 in 2020. It is interesting to mention that despite different levels of NNIs, the relationships were stable between 2019 and 2020

($y = -0.11 + 0.031x$ in 2019 and $y = -0.14 + 0.029x$ in 2020). For 2021, the relationship between NBI and INN was closer to those observed at the end of elongation (Z39, data not shown). Finally, the combination of the 3 years' datasets allowed to obtain a consistent linear relationship between NBI and INN ($R^2 = 0.78$).




Figure 2 : Linear relationships between INN and NBI measured with the Dualex at stage Z32 in 2019, 2020 and 2021 (a) and for these 3 years combined (b)

3.2. VI and wavelengths evaluation

Remote sensing measurements were only made in 2020 and 2021. From the 248 wavelength combinations calculated from 8 VI formulations (Table 3), simple linear regressions were performed to identify among the 248 combinations, the VI and wavelengths of interest. In this work, to consider the operational constraints, namely that the Kernel camera has six lenses, the best performing combinations were selected to minimize the RMSE and by applying a limit of six wavelengths. In practice, in 2020, 2 combinations were selected and 5 in 2021, which represented six and four wavelengths in 2020 and 2021. Indeed, in 2021, the selection of an additional combination would have led to more than six wavelengths. In 2020, GNDVI (940 and 550nm) and TCARI/OSAVI (780, 632, 550, 725 and 850) were selected with respectively a RMSE of 0.164 and 0.165. In 2021, the selected combinations were: GNDVI (940 and 550nm) and 4 combinations made with NG formulation (1: 940 and 550nm, 2: 780 and 550nm, 3: 940 and 615, 4: 780-615nm). In 2021, among the selected combinations RMSE ranged from 0.139 (NG with 940 and 550nm) to 0.145 (NG with 780 and 615nm).

Thus, from the eight combinations tested, three seemed to be relevant at stage Z32: GNDVI, NG and TCARI/OSAVI. Among the wavelengths present in the selected combinations 550nm, 780nm and 940nm were present both years (Table 5).

Table 5: wavelengths occurrence among the selected combinations minimizing the RMSE for linear regressions with INN in 2020 and 2021 for stage Z32

Wavelengths (nm)	550	590	615	632	650	685	725	780	808	850	940
2020	2			1			1	1		1	1
2021	3		2					2			3

3.3. NNI estimation by parametric and non-parametric modelling algorithms

3.3.1. Models training

To improve NNI prediction PLS regressions were constructed with the previously selected combinations, with or without NBI. For the 2 years, studied PLS models with a 6-wavelength limit did not reduce RMSE compared to the best VI studied individually, respectively GNDVI 940-550 in 2020 (RMSE=0.164) and NG 940-550 in 2021 (RMSE=0.139) (Figure 3). However, the RMSEs of the PLS models were equivalent (2020) or better (2021) than the other combinations taken individually. For both years, non-parametric models did not reduce the bias compared to parametric models. By comparison, the introduction of the NBI in each model had reduced the RMSE for all models tested. On the contrary, the bias had increased with the addition of the NBI in 2020 and decreased in 2021.




Figure 3 : RMSE and bias for PLS models constructed with the previously selected combinations minimizing RMSE and for each combination used in these models and studied individually in 2020-2021 (a) and 2021-2022 (b). PLS with 6 wl corresponds to the models created with the combinations minimizing the RMSE with a threshold at 6 wavelengths, models “+NBI” consider the NBI measurements made with Dualex, for each stage the results obtained for each combination in the model were presented. WI : wavelength.

3.3.2. Models cross-validation and validation

Without NBI, as observed for the RMSE, the predictive ability of the non-parametric models was slightly worse than the best VI studied individually. For example, in 2020 the best R^2 was obtained with GNDVI 940-550 ($R^2_{\text{training}}=0.356$) while R^2_{training} reach 0.351 for PLS models. The same trend was observed in 2021: $R^2_{\text{training}}=0.466$ for NG 940-550 and $R^2_{\text{training}}=0.454$ for PLS model. Except for these best combinations, PLS models allowed to increase prediction quality compared to the other combinations studied individually. However, per year, the differences in performance between the models were small. Indeed in 2020 R^2_{training} range from 0.351 to 0.356, while the differences were slightly higher in 2021, from 0.415 to 0.466. Without NBI, NNI prediction were better in 2021 than in 2020.

For all the models studied, the addition of the NBI increased the predictive capacity of the models significantly on the training dataset for both years. It was also true in 2020 on the validation dataset and in 2021 except for PLS model ($R^2_{\text{validation}}=0.723$ for the PLS model with NBI and 0.742 for PLS model without NBI). In 2020, the PLS model with NBI obtained the best performances ($R^2_{\text{validation}}=0.972$, versus 0.832 for the same model without NBI) while it was among the worst models in 2021. On validation dataset, 2021 models were less efficient than in 2020, the best R^2 was obtained for NG 780-550 with NBI ($R^2_{\text{validation}}=0.802$).




Figure 4 : R^2 on the training dataset by leave-one-out cross validation and on the validation dataset (R^2 validation) for PLS models constructed with the previously selected combinations minimizing RMSE and for each combination used in these models and studied individually in 2020-Z32 (a) and 2021-Z32 (b). Wl: wavelength, PLS with 6 wl corresponds to the models created with the combinations minimizing the RMSE with a threshold at 6 wavelengths, models “+NBI” consider the NBI measurements made with Dualex, for each stage the results obtained for each combination in the model were presented

3.3.3. Models testing

For the PLS models with a 6-wavelength limit without NBI, R^2 were higher for the 2020 model tested on the 2021 dataset than the reverse ($R^2_{test}=0.45$ for 2020 model, $R^2_{test}=0.37$ on 2021 model) (Figure 5, a; Figure 6, a). However, because data came from only 2 contrasting years, the predicted values were overestimated for the 2020 model tested on 2021 data while the 2021 model tested on 2020 data underestimated the predicted values. For 2020 and 2021 models, considering the NBI measured with Dualex improved the prediction. Indeed, for 2020 model, R^2 increased from 0.45 to 0.59, while the raise was more pronounced for 2021, from 0.37 to 0.72 (Figure 5 and 6).

By comparing R^2 values obtained on testing dataset, without NBI, limiting PLS models to 6 wavelengths gave equivalent (2020 model tested on 2021) or slightly better performance (2020 model tested on 2021) compared to models with a larger number of VI as inputs variables (data not shown, Bouchard et al., unpublished).




Figure 5: NNI measured and predicted on the 2021 dataset using 2020 PLS models without (a) or with NBI (b)




Figure 6 : NNI measured and predicted on the 2020 dataset using 2021 PLS models without (a) or with NBI (b)

4. Discussion

This study proposed (i) to evaluate the Dualex NNI predictive capacity, (ii) to explore the potential of PLS operational models to predict NNI at the 2 nodes stage (Z32) and (iii) to test if the combination of proximal and remote sensing measurement increased NNI prediction efficiency.

4.1. Predicting NNI by proximal sensing

These results showed a relevant application of the Dualex sensor to estimate crop N status easily and non-destructively at stage Z32. Indeed, a good relationship between NNI and NBI was confirmed during the three-year study, with, all years included, a R^2 reaching 0.78. Moreover, the regression was similar for two out of the three years studied ($y=-0.11+0.031x$ in 2019 and $y=-0.14+0.029x$ in 2020). Thus, NBI seemed to be a relevant N status indicator as the relationship between NBI and NNI was positive ($R^2=0.78$), stable between years and varieties. These results are interesting because, as the Dualex is a pigment meter, most studies are rather focused correlated pigment content estimated by proximal sensing with pigment content measured chemically, especially chlorophylls (Cerovic et al., 2012; Cartelat et al., 2005). Leaf chlorophylls content was used as a N status indicator because chlorophylls and N concentration are highly correlated ($R^2=0.93$, on 30 upper leaves from the end of stem elongation to flowering, Cartelat et al., 2005). Moreover, Dualex also measured the leaf polyphenolic content as another indicator of the N status. This additional measurement, compared with other techniques, seemed to be really powerful because polyphenolic accumulation increases in case of N deficiency ($R^2=0.76$, on 30 upper leaves from the end of stem elongation to flowering, Cartelat et al., 2005).

Although relations were very dependent on the stages, Cartelat et al. (2005) highlighted that NBI, by combining chlorophyll and polyphenol contents, should accentuate the differences between the different levels of N status due to the inverse relationships of chlorophylls and polyphenolic contents with the crop N content. Thus, in this study, it was particularly interesting to show that crop N status could be accurately estimated by the NBI measured with the Dualex. This is consistent with the study of Jiang et al. (2021), evaluating 3 portables optical sensors for diagnosis winter wheat leaf and crop N content. In their study, at jointing stage, the best predictions of leaf N content were obtained by NBI measured with the Dualex and NDRE measured with a spectrophotometer (rapidSCAN CS-45) ($R^2=0.79$). Quemada et al. (2019) also evaluated proximal and remote sensing accuracy to estimate wheat N status (crop N content, crop N concentration and NNI). Between Greenseeker and Dualex, the best NNI predictions were stage dependant. Indeed, NBI was better at elongation stage ($R^2=0.51$) and NDVI calculated with Greenseeker was better at flowering ($R^2=0.56$). However better correlation with NBI was observed with N content than with NNI (Quemada et al., 2019). This is consistent with results

obtained by Cartelat et al. (2005) with a R^2 that only reached 0.56 between NBI and NNI. In this study, NBI performed very well to predict NNI ($R^2=0.78$) at stage Z32, better than other studies, this is interesting as NNI is a relevant indicator for monitoring N status (Colaço and Bramley, 2018). As demonstrated in other studies, it is sensitive to N inputs and can identify N deficiencies (Justes et al. 1994; Lemaire et al., 2008). Thus, these results present an interesting application in case of a dynamic management approach, especially because this proximal measurement was fast, requires little data processing and the tool is easy to use (Padilla et al., 2018). However, because measurements are taken at leaf scale, they are more dependent on stage, variety, and water stress (Muñoz-Huerta et al., 2013). In their study Jiang et al. (2021) showed that measurements taken by spectrophotometer made it possible to consider larger sampling area and therefore were more stable throughout the crop cycle. Moreover, in this study even if Dualex was very accurate to predict NNI, the application of these tools was limited for whole-field management (Tremblay et al., 2011; Muñoz-Huerta et al., 2013). Indeed, the measurements taken by these tools represent only a small part of the leaves on a field scale, that's why Dualex poorly consider the spatial variability. On the contrary remote sensing is a practical means to assess N status spatial variability (Chen, 2015).

4.2. Operational non-parametric model to predict NNI

Some studies have highlighted the potential of VI to monitor crop N status by making parametric correlations between VI with: leaf or crop N content ($\text{g}\cdot\text{m}^{-2}$) (Zheng et al., 2018; Quemada et al., 2019 ; Zheng et al., 2018 ; Bao et al., 2013; Yang et al., 2019; Argento et al., 2020), leaf or crop N concentration (%N per dry biomass) (Niu et al., 2019; Quemada et al., 2019; Gordillo-Salinas et al., 2021; Li et al., 2014) and NNI (Argento et al., 2020; Chen, 2015 ; Gordillo-Salinas et al., 2021).

Most of the study correlate VI with leaf N content. However, due to the dilution effect considering only leaf N content gives few information on N crop status (Colaço et Bramley., 2018). NNI, with considering both biomass and N content is mostly adapted to monitor crop N status with the aim of enabling dynamic management of fertilisation as it allows to compare different crops' N status independently of differences in crop biomass (Colaço et Bramley, 2018). This last point is interesting in case of a dynamic fertiliser management approach because it simplifies the measurement for the farmer: the measurement can be done when the conditions are favourable around the target stage and allow comparisons even if the biomasses are not the same.

However, to date a few parts of these works correlate UAV-based VI with NNI. Among the studies considering UAV-based VI, the correlations calculated with NNI are very good. NDRE ($R^2=0.75$) was the best-performing index in the study of Argento et al. (2020), REIP-LI (Guyot et al., 1988) in Chen (2015) study (R^2 from 0.83 to 0.93), GNDVI ($R^2=0.91$) for Gordillo-Salinas (2021) were the most responsive. In this study among 248 combinations were evaluated to predict NNI, GNDVI with 940-550nm in 2020 and NG 940-550nm in 2021 reduced the prediction error and allowed to intermediate prediction performances on training dataset ($R^2_{\text{training}}=0.35$ and 0.47) while quality prediction increase on validation dataset ($R^2_{\text{validation}}=0.88$ and 0.72). However, despite good performance highlighted in the works, NNI estimation by remote sensing are highly variables (Chen, 2015), change between the seasons (Mistele and Schmidhalter, 2008), and are highly dependent on spectral band width, VI formulation and fitting function (Liu et al., 2016).

In this context, even if UAV measurements allow to consider spatial heterogeneity, use simple VI to predict NNI present some limits. Non-parametric models should present interesting opportunities for use as more wavelengths are considered (Zheng et al., 2018). From such method, N status prediction should be less specific and prediction accuracy aims to increase. However, to date few studies work on the application of non-parametric models from UAV measurements (Liu et al., 2016; Gnyep et al., 2016

in Zheng et al., 2018). Liu et al. (2016), Yang et al. (2019) and Zheng et al. (2018) conclude that most of the UAV-based predicted algorithms tested out-performed the optimal VI studied individually. Zheng et al. (2018) present RF as the best performing model ($R^2_{\text{validation}}=0.79$), while PSO-SVR combining wavelengths and VI was the most accurate for Yang et al. (2019) ($R^2_{\text{training}}=0.90$ and $R^2_{\text{validation}}=0.80$). However, some studies are based only on cross-validation (one set of data) and do not necessarily take into account the problems of over-fitting. This work does not seek to compare different models but to estimate the performance of a model considering a limited number of VI to be operational. Indeed, most of the studies (i) explore a wide range of wavelengths by proximal sensing but the application of these models is limited to whole-field management, or (ii) create complex models from UAV-based measurements with seems to be difficult to apply in practice.

According to previous work (Bouchard et al., unpublished), among different non-parametric models tested, PLS models were relevant to predict NNI in our situation. These methods are suitable for remote sensing measurements as the reflectivity in different wavelengths are often correlated. Moreover, these methods are adapted when the number of variables in the dataset exceeds the number of individuals (Li et al., 2014; Makowski et al., 2021). In this work, models' validation showed that PLS optimized models with 6 wavelengths provided good NNI predictions ($R^2_{\text{validation}}=0.83$ in 2020 and 0.74 in 2021). However, the predictive ability of the non-parametric models was slightly worse than the best index studied individually. Except for these best combinations, PLS models allowed to increase prediction quality compared to the other combinations studied individually. This is consistent with the study of Yao et al. (2015) and Hansen and Schjoerring (2003), who find that non-parametric models don't perform better than the best wavelengths combination. However, Yao et al. (2015) concluded that even if it is possible to obtain very good results with simple VI, it is preferable to use a wider range of wavelengths to consider more information than simple VI. It is also true when 2020 models are applied on 2021 dataset and vice versa. One explanation comes from the data set used to parameterise the model, which was based on only one year of measurements. Thus, the model which should be less specific than an index alone was very dependent on the quality of the dataset used for training, especially when it is extrapolated after to other varieties, sites, or growth stage (Yao et al., 2015, Li et al. 2014). In the case of this study, the models were extrapolated between 2 contrasting years, as illustrate for example by the overall precipitation between March and July: it was 205.8mm in 2020 while it rained 324.1mm in 2021 at the same period (Meteociel, 2021). Thus, a larger dataset would increase the quality of prediction. A second explanation comes from the fact that we focus only on one stage, at the beginning of the cycle, whereas according to other studies, the improvements allowed by the models are more marked at the end of the cycle and make it possible to overcome the problems of saturation that occurred when VI are studied individually (Hansen and Schjoerring, 2003).

4.3. Improving NNI prediction accuracy by combining proximal and remote sensing

According to literature reviewed, few works propose a multi-sensor approach and most of them combine sensors to monitor different variables (Wang et al., 2019; De Benedetto et al., 2013; Pancorbo et al., 2021). For example, Pancorbo et al. (2019) used hyperspectral and thermal cameras to monitor winter wheat N and water status by remote sensing. Some studies combine, measurements taken by sensors embedded on tractors or all-terrain-vehicle with satellite-based VI (De Benedetto et al., 2013; Wang et al., 2019). However, this work is innovative in the sense that it combines measurements of the same variable taken at different scales to improve accuracy.

The results of this work show a particular Interest in the use of proximal and remote sensing to assess wheat N status. Dualex is very accurate to predict NNI while UAV-based prediction can consider spatial

variability and offer interesting opportunities by taking measurement in a wide range of wavelengths. However, Dualex application is limited for whole-field management, while UAV-based prediction is less stable between the years and varieties than measurements made by proximal sensing. Thus, combining these 2 measurement scales would be innovative and interesting, as it should allow to take advantages of these 2 measurements scale: proximal sensing stability and accuracy and spatial heterogeneity consideration by remote sensing.

The addition of the NBI in non-parametric models presents really interesting perspectives by increasing the predictive quality of parametric and non-parametric models (except for the PLS model in 2021). Among the models tested, the addition of the NBI achieved the best performances: R^2 validation reached 0.97 in 2020 for PLS model with NBI and NG 550-780nm with NBI obtained the best R^2 validation (0.80) in 2021. Thus, when testing models for both years studied, the application of the PLS model with NBI improves NNI prediction. Indeed, R^2 raise from 0.45 to 0.59 for 2020 models tested on 2021 dataset, while adding NBI in 2021 PLS models allows to reach a R^2 of 0.72 (0.37 without NBI). Moreover, predicted NNI values are more consistent with models adding NBI than models without NBI, especially when the 2020 model was test on 2021 dataset. Is it important to mention that few studies validate the models on another independent dataset and most of the works only consider R^2 to assess prediction quality. But to sometimes good correlation did not allow to estimate consistent NNI values as it was the in this study when two contrasting datasets were used to validate each other. However, to use NNI prediction for N fertilization monitoring, predicted consistent NNI values is important as a threshold value allows to identify N deficiency. In this context the use of models combining measurements taken by proximal and remote sensing present interesting perspectives by taking advantages of these 2 measurements scale: proximal sensing stability and accuracy and spatial heterogeneity consideration by remote sensing with convincing results. To date no studies combine measurements taken by proximal and remote sensors to predict N status. Further work will focus on the practical implementation, in farmer field, of these models combining 2 measurement scales, especially by defining how many proximal measurement points are necessary.

5. Conclusion:

Improving NUE to minimize the N pollution to the environment while maintaining high crop yield and satisfy quality at harvest is essential for the development of sustainable agriculture (Masclaux-Daubresse et al., 2010; Sharma et Bali, 2018). To achieve this goal, assessing N status in real time is important to adapt exactly the N fertilizer rate in space, time and to match crops' demand. In this context, proximal and remote sensing offers good opportunities to monitor N status easily and non-destructively.

As demonstrate in other studies (Quemada et al., 2019; Jiang et al., 2021), proximal sensing present good accuracy to monitor N status at stage 2 nodes, during elongation. This work shows that Dualex, through the NBI measurement (Chlorophylls/Flavonols) present a relevant application to predict NNI, as the relation between NNI and NBI is good ($R^2=0.78$) and stable between years and varieties. However even if proximal sensing provides good measurement accuracy, in practice, the application of these tools is limited. Firstly, because leaf-clip sensors only consider a limited number of wavelengths a few number of VI are calculated, which makes these tools very specific (Fu et al., 2020). Secondly these tools are limited in terms of measurement area, as they poorly consider the spatial variability so proximal sensing is not really suited for a whole-field management (Muñoz-Huerta et al., 2013).

On the other hand, UAV flights, allow measurements with high spatial and temporal resolution (Zheng et al. 2018). Because it is difficult to identify a consistent and sustainable wavelength combination to monitor NNI, PLS models seem to offer interesting application by combining different VI. In this context, for the 2 years studied, different PLS models were tested, combining the combinations minimising the RMSE by creating models with no more than 6 wavelengths. These achieve similar results as the best of the VI combinations considered in the model. Because only 2 contrasting datasets were used to construct and validate models, embed more data from other years should probably increase the prediction accuracy. Finally, non-parametric models offer the opportunity to combine the benefits of proximal and remote sensing. This study highlights the interest of this innovative combination, which allow to take advantages of these 2 measurements scale: proximal sensing accuracy and spatial heterogeneity consideration by remote sensing. Combining proximal and remote sensing measurement have increase prediction accuracy when the models were tested on another situation (other year dataset). The results from this study could be applied for dynamic fertilisation management. Further work will focus on the practical implementation, in farmer field, of these models combining 2 measurement scales, especially by defining how many proximal measurement points are necessary.

References:

- Aranguren M., Castellon A., Aizpurua A., 2020. Crop sensor based non-destructive estimation of nitrogen nutritional status, yield, and grain protein content in wheat. *Agriculture*, 10, pp. 148-170. Doi.org/10.3390/agriculture10050148.
- Argento F., Anken T., Abt F., Vogelsanger E., Walter A., Liebisch F., 2020. Site-specific nitrogen management in winter wheat supported by low-altitude remote sensing and soil data. *Precision Agriculture*, 22, pp. 364-386. Doi.org/10.1007/s11119-020-09733-3.
- Bao Y., Xu K., Min J., Xu J., 2013. Estimating wheat shoot nitrogen content at vegetative stage from in situ hyperspectral measurements. *Crop Science*, 53, pp. 2063-2071. Doi.org/10.2135/cropsci2013.01.0012
- Barnes E.M., Clarke T.R., Richards S.E., Colaizzi P.D., Haberland J., Kostrzewski M., Waller P., Choi C., Riley E., Thompson T., Lascano R.J., Li H., Moran M.S., 2000. Coincident detection of crop water stress, nitrogen status and canopy density using ground-based multispectral data. *Proceedings of the Fifth International Conference on Precision Agriculture*, ASA, Madison, WI.
- Bouchard M.A., Andriamandrosa A.L.H., Andrianarisoa S., Waterlot C., Siah A., Guille C., Vandoorne B., 2021. Evaluating UAV-based vegetation indices and exploration of new wavelengths combination to monitor winter wheat crop nitrogen status. In: J.V. Stafford (Ed.) *Precision Agriculture '21: Proceedings of the 13th European Conference on Precision Agriculture*, Wageningen, The Netherlands: Wageningen Academic Publishers. Pp. 469-476.
- Bouchard M.A., Andriamandrosa A.L.H., Vandoorne B., Unpublished. Comparative analysis of parametric and non-parametric models to assess and predict the nitrogen nutrition index (NNI) during winter wheat growth using UAV-based multispectral images.
- Brun F., Makowski D., Wallach D. and Jones J.W., 2018. ZeBook: Working with dynamic models for agriculture and environment. R package version 1.1. Available online: <https://CRAN.R-project.org/package=ZeBook> (accessed on 18/12/2021)
- Buschmann, C. & Nagel, E., 1993. In vivo spectroscopy and internal optics of leaves as basis for remote sensing of vegetation. *International Journal of Remote Sensing*, 14, pp. 711–722. Doi.org/10.1080/01431169308904370.
- Cartelat A., Cerovic Z. G., Goulas Y., Meyer S., Lelarge C., Prioul J. L., 2005. Optically assessed contents of leaf polyphenolics and chlorophyll as indicators of nitrogen deficiency in wheat (*Triticum aestivum* L.). *Field Crops Research*, 91, pp. 35–49. Doi.org/10.1016/j.fcr.2004.05.002.
- Cerovic Z.G., Masdoumier G., Ben Ghazlen N., Latouche G., 2012. A new optical leaf-clip meter for simultaneous non-destructive assessment of leaf chlorophyll and epidermal flavonoids. *Physiologia Plantarum*, 146, pp. 251–260. Doi.org/10.1111/j.1399-3054.2012.01639.x.
- Chen P., 2015. A comparison of two approaches for estimating the wheat nitrogen nutrition index using remote sensing. *Remote sensing*, 7, pp. 4527-4548. Doi.org/10.3390/rs70404527.
- Cohan J.P., Soenen B., Le Souder C., Vericel G., Laurent F., 2018. Improving nitrogen use efficiency in wheat: recent progress and prospects in France. In : *Phloème 2018*, Paris, France.

- Colaço A.F., Bramley R.G.V., 2018. Do crop sensors promote improved nitrogen management in grain crops? *Field Crops Research*, 218, pp. 126-140. Doi.org/10.1016/j.fcr.2018.01.007.
- Comifer, 2013. Calcul de la fertilisation azotée. Guide méthodologique pour l'établissement des prescriptions locales. Cultures annuelles et prairies. Available online: http://www.comifer.asso.fr/images/publications/brochures/BROCHURE_AZOTE_20130705_eb.pdf (accessed on 08/04/2021)
- De Benedetto D., Castrignano A., Diacono M., Rinaldi M., Ruggieri S., Tamborrino R., 2013. Field partition by proximal and remote sensing data fusion. *Biosystems Engineering*, 114 (4), pp. 372-383. Doi.org/10.1016/j.biosystemseng.2012.12.001.
- FAO, 2019. World fertilizer trends and outlook to 2022. Available online: <http://www.fao.org/3/ca6746en/ca6746en.pdf> (accessed on le 27/06/21)
- Fu Z., Jiang J., Gao Y., Krienke B., Wang M., Zhong K., Cao Q., Tian Y., Zhu Y., Cao W., Liu X., 2020. Wheat growth monitoring and yield estimation based on multi-rotor unmanned aerial vehicle. *Remote Sensing*, 12, pp. 508-526. Doi.org/10.3390/rs12030508.
- Gastal F., Lemaire G., Durand J.L., Louarn G., 2015. Quantifying crop responses to nitrogen and avenues to improve nitrogen-use efficiency. *Crop Physiology*, Chap. 8, pp. 161-206. Doi.org/10.1016/B978-0-12-417104-6.00008-X.
- Gordillo-Salinas V.M., Flores-Magdaleno H., Ortiz-Solorio C.A., Arteaga-Ramírez R., 2021. Evaluation of nitrogen status in a wheat crop using unmanned aerial vehicle images. *Chilean Journal of Agricultural Research*, 81(3), pp. 408-419. Doi.org/10.4067/S0718-58392021000300408.
- Haboudane D., Tremblay N., Miller J.R., 2008. Remote estimation of crop chlorophyll content using spectral indices derived from hyperspectral data. *IEE Transactions on Geoscience and Remote Sensing*, 46(2), pp. 423-437. Doi.org/10.1109/TGRS.2007.904836..
- Hansen P.M., Schjoerring J.K., 2003. Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. *Remote Sensing of Environment*, 86, pp. 542-553. Doi.org/10.1016/S0034-4257(03)00131-7.
- Hawkesford M., Horst W., Kichey T., Lambers H., Schjoerring J., Skrumsager Moller I., White P., 2012. Functions of macronutrients. *Marschner's mineral nutrition of higher plants*. 3. Ed. Amsterdam : Elsevier, Academic Press. ISBN 978-0-12-384905-2.
- Jiang J., Wang C., Wang H., Fu Z., Cao Q., Tian Y., Zhu Y., Cao W., Liu X., 2021. Evaluation of three portable optical sensors for non-destructive diagnosis of nitrogen status in winter wheat. *Sensors*, 21. Doi.org/10.3390/s21165579.
- Justes E., Mary B., Meynard J-M., Machet J-M., Huché-Théliér L., 1994. Determination of a critical nitrogen dilution curve for winter wheat crops. *Annals of Botany*, 74, pp. 397-407. Doi.org/10.1006/anbo.1994.1133.
- Kuhn M., 2008. Building predictive models in R using the caret package. *Journal of Statistical Software*, 28(5), pp. 1 – 26. Doi.org/10.18637/jss.v028.i05
- Lemaire G., 2019. Une nouvelle approche de la fertilisation des cultures. *Agronomie, Environnement & Sociétés, Association Française d'Agronomie (Afa)*, 9.

- Lemaire G., Ciampitti I., 2020. Crop mass and N status as prerequisite covariables for unravelling nitrogen use efficiency across genotype-by-environment-by-management scenarios: A Review. *Plants*, 9, pp. 1309-1327. Doi.org/10.3390/plants9101309.
- Lemaire G., Jeuffroy M.H., Gastal F., 2008. Diagnosis tool for plant and crop N status in vegetative stage theory and practices for crop N management. *Eur. J. Agron*, 28, pp. 614–624. Doi.org/10.1016/j.eja.2008.01.005.
- Li F., Mistele B., Hu Y., Chen X., Schmidhalter U., 2014. Reflectance estimation of canopy nitrogen content in winter wheat using 103 optimized hyperspectral spectral indices and partial least squares regression. *European Journal of Agronomy*, 52, pp. 198-209. Doi.org/10.1016/j.eja.2013.09.006.
- Liu Y., Cheng T., Zhu Y., Tian Y., Cao W., Yao X., Wang N. Comparative analysis of vegetation indices, non-parametric and physical retrieval methods for monitoring nitrogen in wheat using UAV based multispectral imagery. In : *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2016, pp. 7362-7365
- Makowski D., Brun F., Doutart E., Duyme F., El Jabri M., Fauvel K., Legris M., Philibert A., Piraux F., Ternier A., 2021. *Data science pour l’agriculture et l’environnement*. Ellipses: Paris.
- Masclaux-Daubresse C., Daniel-Vedele F., Dechorgnat J., Chardon F., Gaufichon L., Suzuki A., 2010. Nitrogen uptake, assimilation and remobilization in plants: challenges for sustainable and productive agriculture. *Annals of Botany*, 105, pp. 1141-1157. Doi.org/10.1093/aob/mcq028.
- Meteociel. 2021. Données mensuelles pour Lille. Available online: https://www.meteociel.fr/climatologie/obs_villes.php?code=7015&mois=12&annee=2021 (accessed on 08/01/2022)
- Mevik B.-H., Wehrens R. and Hovde Liland K., 2020. PLS: Partial Least Squares and Principal Component Regression. R package version 2.7-3. Available online: <https://CRAN.R-project.org/package=pls> (accessed on 18/12/2021)
- Mistele B., Schmidhalter U., 2008. Estimating the nitrogen nutrition index using spectral canopy reflectance measurements. *European Journal of Agronomy*, 29, pp. 184-190. Doi.org/10.1016/j.eja.2008.05.007.
- Moll R.H., Kamprath E.J., Jackson W.A., 1982. Analysis and interpretation of factors which contribute to efficiency of nitrogen utilization. *Agronomy Journal*, 74(3), pp. 562-564. Doi.org/10.2134/agronj1982.00021962007400030037x.
- Muñoz-Huerta R.F., Guevara-Gonzalez R.G., Contreras-Medina L.M., Torres-Pacheco I., Prado-Olivarez J., Ocampo-Velazquez R.V., 2013. A review of methods for sensing the nitrogen status in plants: advantages, disadvantages and recent advances. *Sensors*, 13, pp. 10823-10843. Doi.org/10.3390/s130810823.
- Niu, Q., Feng, H., Li, C., Yang, G., Fu, Y., Li, Z., Pei, H., 2019. Estimation of leaf nitrogen concentration of winter wheat using uav-based RGB imagery. *IFIP Advances in Information and Communication Technology*, 546, pp. 139-153. Doi.org/10.1007/978-3-030-06179-1_15.
- Omara P., Aula L., Oyebiyi F., Raun W.R., 2019. World cereal nitrogen use efficiency trends: review and current knowledge. *Agrosystems, Geosciences & Environment*, 2 (1). Doi.org/10.2134/age2018.10.0045.

- Padilla F.M., Gallardo M., Pena-Fleitas M.T., De Souza R., Thompson R., 2018. Proximal optical sensors for nitrogen management of vegetable crops: A review. *Sensors*, 2083, pp. 1-23. [Doi.org/10.3390/s18072083](https://doi.org/10.3390/s18072083).
- Pancorbo J.L., Camino C., Alonso-Ayuso M., Raya-Sereno M.D., Gonzalez-Fernandez I., Gabriel J.L., Zarco-Tejada P.J., Quemada M., 2021. Simultaneous assessment of nitrogen and water status in winter wheat using hyperspectral and thermal sensors. *European Journal of Agronomy*, 127. [Doi.org/10.1016/j.eja.2021.126287](https://doi.org/10.1016/j.eja.2021.126287).
- Quemada M., Pancorbo J.L., Alonso-Ayuso M., Gabriel J.L., Lopez-Herrera J, Perez-Martin E. Vegetation indices from remote sensing imagery as proxies for yield and grain N in wheat. In: *Precision Agriculture '19: Proceedings of the 12th European Conference on Precision Agriculture*, edited by J.V. Stafford, BIOS Scientific Publishers Ltd, Oxford, UK, 323-330.
- Ravier C., Quemada M., Jeuffroy M.-H. 2017. Use of a chlorophyll meter to assess nitrogen nutrition index during the growth cycle in winter wheat. *Field Crops Research*, 214, pp. 73-82. [Doi.org/10.1016/j.fcr.2017.08.023](https://doi.org/10.1016/j.fcr.2017.08.023).
- Rodriguez D., Fitzgerald G.J., Belford R., Chistensen L.K., 2006. Detection of nitrogen deficiency in wheat from spectral reflectance indices and basic crop eco-physiological concepts. *Australian Journal of Agricultural Research*, 57, pp. 781–789. [Doi.org/10.1071/AR05361](https://doi.org/10.1071/AR05361).
- Rondeaux G., Steven M., Baret F., 1996. Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*, 55, pp. 95-107. [Doi.org/10.1016/0034-4257\(95\)00186-7](https://doi.org/10.1016/0034-4257(95)00186-7).
- Rouse J.W., Haas R.H., Schell J.A., Deering D.W., 1973. Monitoring vegetation systems in the great plains with ERTS. *ERTS symposium*, NASA, SP-351, Washington DC 1 309-317.
- Sharma L.K., Bali S.K., 2018. A review of methods to improve nitrogen use efficiency in agriculture. *Sustainability* 10 (51). [Doi.org/10.3390/su10010051](https://doi.org/10.3390/su10010051).
- Stripada R., Heiniger R., White J. & Meijer A., 2006. Aerial colorinfrared photography for determining early in-season nitrogen requirements in corn. *Agronomy Journal*, 98, pp. 968–977. [Doi.org/10.2134/agronj2005.0200](https://doi.org/10.2134/agronj2005.0200).
- Tremblay N., Fallon E., Ziadi N., 2011. Sensing of crop nitrogen status: opportunities, tools, limitations, and supporting information requirements. *Proceedings of the European Society for Agronomy Congress*, Bologna, Italy.
- Vance, C.P., 2001. Symbiotic nitrogen fixation and phosphorus acquisition: plant nutrition in a world of declining renewable resources. *Plant Physiology* 127, pp. 390–397. [Doi.org/10.1104/pp.010331](https://doi.org/10.1104/pp.010331).
- Wang H., Mortensen A.K., Mao P., Boelt B., Gislum R., 2019. Estimating the nitrogen nutrition index in grass seed crops using a UAV-mounted multispectral camera. *International Journal of Remote Sensing*, 40 (7), pp. 2467-2482. [Doi.org/10.1080/01431161.2019.1569783](https://doi.org/10.1080/01431161.2019.1569783)
- Yang B., Wang M., Sha Z., Wang B., Chen J., Yao X., Cheng T., Cao W., Zhu Y., 2019. Evaluation of aboveground nitrogen content of winter wheat using digital imagery of unmanned aerial vehicles. *Sensors*, 19, pp. 4416-4433. [Doi.org/10.3390/s19204416](https://doi.org/10.3390/s19204416).
- Yao X., Huang Y., Shang G., Zhou C., Cheng T., Tian Y., Cao W., Zhu Y., 2015. Evaluation of six algorithms to monitor wheat leaf nitrogen concentration. *Remote Sens.*, 7, pp. 14939-14966. [Doi.org/10.3390/rs71114939](https://doi.org/10.3390/rs71114939).

- Zadoks J.C., Chang T., Konzak C.F., 1974. A decimal code for the growth stages of cereals. *Weed Research*, 14, 415-421. [Doi.org/10.1111/j.1365-3180.1974.tb01084.x](https://doi.org/10.1111/j.1365-3180.1974.tb01084.x)
- Zheng H., Li W., Jiang J., Liu Y., Cheng T., Tian Y., Zhu Y., Cao W., Zhang Y., Yao X., 2018. A comparative assessment of different modeling algorithms for estimating leaf nitrogen content in winter wheat using multispectral images from an unmanned aerial vehicle. *Remote Sensing*, 10, pp. 2026-2041. [Doi.org/10.3390/rs10122026](https://doi.org/10.3390/rs10122026).

Chapitre IV

Impact des pratiques de fertilisation azotée sur la mise en place des
composantes de rendement du blé tendre d'hiver

Avec le développement de capteurs et de modèles de plus en plus performants pour estimer le statut azoté en cours de croissance de la culture, le pilotage dynamique de la fertilisation azotée, basé sur le suivi de l'indice de nutrition azoté (INN) de la culture en cours de croissance, présente des perspectives intéressantes. Les **chapitres 1, 2 et 3** mettent en évidence le potentiel des mesures prises par proxi- et télédétection dans le suivi de l'INN. Une méthode de pilotage dynamique permettrait d'adapter en temps réel des apports d'azote (N), de façon précise, en prenant en compte les conditions pédoclimatiques et avec la possibilité de considérer les variations spatiales et temporelles des besoins en N (Lemaire, 2019). En pratique cela devrait permettre d'améliorer la valorisation des apports (NUE) et ainsi limiter les risques de pollution azotée, sans impact sur la production. Ce changement de paradigme, proposé entre autres par Ravier et al. (2018) sur le blé tendre, offre l'opportunité de s'affranchir de l'objectif de rendement et du reliquat azoté en sortie hiver ; 2 variables controversées dans le calcul de la dose bilan (Ravier et al., 2016). En effet, dans la pratique, les agriculteurs utilisent plutôt le rendement espéré à la place de l'objectif de rendement qui est défini comme le rendement moyen de la culture considérée sur les cinq années précédentes, en ayant enlevé les deux années présentant les rendements extrêmes (Ravier et al., 2016). Meynard et Jeuffroy (2019) ont mis en évidence d'autres limites : le risque de ne pas atteindre le rendement potentiel des années favorables, une mauvaise valorisation du progrès génétique et le risque de voir les rendements stagner. Enfin, se baser sur l'objectif de rendement défini en amont de la campagne ne permet pas de prendre en compte les conditions climatiques du printemps qui agissent sur la production. Au-delà des limites liées à son utilisation, de récentes études ont mis en évidence que certaines connaissances sur la fertilisation ne sont pas valorisées dans la méthode du bilan (Ravier et al., 2016). En effet, la notion de carences tolérables et de l'augmentation de l'efficacité des apports lorsqu'ils sont décalés ne sont pas prises en compte. Dans ce contexte, une trajectoire d'INN optimale a été proposée pour la culture de blé, permettant de tolérer des carences en N en début de cycle ; ces carences semblant sans préjudice sur le rendement final (Jeuffroy et Bouchard, 1999 ; Ravier et al., 2017a).

Cependant, les apports étant définis au cours de la croissance de la culture, il paraît pertinent de piloter la fertilisation azotée non pas en fonction du rendement final projeté, mais en fonction des composantes de rendement s'établissant au cours de la croissance de la culture. Ainsi, même si l'étude des composantes de rendement a déjà largement été investiguée (Orloff et al., 2012 ; Slafer et al., 2014 ; Ferrante et al., 2017 ; Golba et al., 2013), il paraît intéressant de compléter les chapitres précédents par une étude des relations entre la mise en place de ces composantes et les pratiques de fertilisation associées. Dans ce chapitre, la valorisation des apports en fonction des stratégies de fertilisation sera également étudiée.

Ces résultats pourront par la suite servir de base pour la prise en compte des composantes de rendement, en lien avec les pratiques de fertilisation, dans la mise en place future d'une démarche de pilotage dynamique.

Impacts of the fertilization practices on nitrogen uptake and the establishment of yield components of winter wheat

Bouchard Marie-Astrid ^{1*}, Andriamandroso A.L.Herinaïna ¹ and Vandoorne Bertrand ¹

¹Université de Liège, Junia, UMRT 1158 BioEcoAgro – Conduction, optimization and design of cropping systems meeting multi-criteria objectives, B-5030 Gembloux, Belgique

*Correspondence : marie-astrid.bouchard@junia.com

Abstract

Increase the Nitrogen (N) use efficiency (NUE) to minimize the N pollution while maintaining high crop yield and satisfy quality at harvest is essential for the development of sustainable agriculture. To date the total amount of fertilizer is generally split in 3 or 4 applications, according to growing stages, to synchronize application dates and rates. However, a better consideration of the spatial and temporal variability of N requirements would allow to maximise apparent N recovery (ANR). In this context, some studies are working on new dynamic N fertilization management methods based on a regular N status monitoring and comparison with a threshold crop N status to identify N deficiencies. In association with decision rules to apply N fertilizer at the time of optimal N recovery conditions and when there is a high crop N requirement, this method aims increase ANR. To date, research on dynamic N fertilization management method includes tolerable deficiencies. However, as yield is determined by yield component setup from the early stage and because there is no consensus on splitting fertilization in three-four applications, this work aims at (i) studying yield and yield components and (ii) comparing harvest performance and ANR under different N fertilization strategies, for two agropedoclimatical situations. The fertilization strategies represent varying levels of N fertilisation and different splitting: 13 combinations in 2020 and 19 in 2021. Among studied yield components (spikes.m⁻², plants.m⁻², grains.spike⁻¹, grain weight), the results showed that the number of spikes. M⁻² was the most yield determinant. For both studied years, fertilization practices have a significant effect on this component from the tillering stage. For all studied fertilization practices, harvest performance analysis confirmed this. Indeed, although yield response differed between the two years when the N fertilizer rate increased, the high input strategy at tillering was efficient for the two considered trials. In this context, N supply at the end of winter is critical to reach the potential yield. Even if some trend emerges between the two trials, the contrasted weather and sowing conditions had considerably influenced crop growth and ANR. Because N recovery increased at later stages, more study should help to find a compromise between productivity and ANR increase.

1. Introduction

Increasing the Nitrogen (N) use efficiency (NUE) to minimize the N pollution while maintaining high crop yield and satisfying quality at harvest is essential for the development of sustainable agriculture (Masclaux-Daubresse et al., 2010; Sharma and Bali, 2018). Most studies focused on genetic progress to improve the valorisation of N inputs by wheat (Slafer et al., 2014; Sylvester-Bradley and Kindred, 2009). However, it appears clearly that adapting fertilizer practices also could enhance NUE by adapting the N fertilizer rate in space and time to match crops' demand (Masclaux-Daubresse et al., 2010; Sharma and Bali, 2018; de Oliveira Silva et al., 2020).

NUE corresponds to the increase in yield per unit of available N for the crop, this N coming from the soil directly and from fertilizer supply (Moll et al., 1982). It is the result of N uptake (NupE) and N utilization efficiency (NutE).

- NutE is the amount of grain produced per unit of N uptake (Moll et al., 1982; Hirel et al., 2007; Sylvester-Bradley and Kindred 2009).
- NupE is the proportion of N available taken by the crop. In practice, according to the studies, N available is not always defined in the same way. Sometimes it considers soil and fertilizer supply while it can also be the soil mineral N content at the beginning of the growing period, without fertilizer. By considering N uptake from fertilizer, NupE is equivalent to the apparent fertilizer N recovery (ANR). ANR corresponds to the increase in plant N uptake per unit of N applied (Habbib et al., 2017).

To increase NUE, the total amount of fertilizer is generally split into 3 or 4 applications for wheat crops according to growing stages (90% of the 400 French farmers surveyed, Degan et al., 2019). This aims at synchronizing application dates and rates with the crop's N requirements to maximize NUE (Sharma and Bali, 2017; Sieling and Kage, 2021). The application dates are generally based on the crop's reference stage, i.e. tillering (Z21), beginning of stem elongation (Z31) and spike emergence (Z51) (Sieling and Kage, 2021; Zadoks, 1974). The application at the tillering (Z21) stage, corresponding to the beginning of the spring, is limited because the needs at this stage are still low (Figure 1). At the beginning of stem elongation (Z31), wheat starts the jointing phase, which is characterized by an important increase in N requirements, so this is commonly the most significant input of the fertilizer scheme (45% of the total N amount on average, Degan et al., 2019). Late N inputs, between booting (Z41) and flowering (Z61), act on protein content (Brown et al., 2005; Orloff et al., 2012; Sieling and Kage, 2021). Finally, at flowering, when N uptake slows and the vegetative growth is finished, N is translocated from older plant tissues to the grains (Brown et al., 2005).




Figure 1: Percent of total biomass and N uptake during the season in relation to growth stages (Brown et al., 2005)

However, late-season applications are better recovered than inputs made during the early stages, at the end of winter. Sieling and Kage (2021) studied the ANR for each N application on wheat for different varieties. ANR reached a maximum of 62% at tillering, 77% at the beginning of elongation, and 82% at spike emergence. Two hypotheses were highlighted by Limaux (1999) to explain this: (i) the inputs recovery increases when the biomass increases, and (ii) when there is low N uptake, fertilizer remains in the soil and is more sensitive to leaching, losses in gaseous forms or become unavailable through immobilization (King et al., 2001 in Efreteui et al., 2016). Although ANR depends on the crop growth rate at the time of N application, some studies highlighted the importance of rain during a short period just after N applications to increase ANR (Bouthier, 1997 in Cohan et al., 2018).

It was also shown that N uptake during vegetative growth affects yield productivity with the setup of the different yield components (Orloff et al., 2012). Indeed, yield can be divided into several numerical components related to each other (Figure 2): i.e. (i) the spikes number per surface unit, which is led by the plant per surface unit and the number of spikes per plant, (ii) the number of grains per spike resulting from spikelets' per spike and grains per spikelet, from such components (I and ii) grains number per surface unit is calculated and (iii) the average grain weight.




Figure 2 : Relationship between yield components and their implementation during crop growth cycle (According to Slafer et al., nd; Slafer et al., 2014)

It is known that an increase in yield is mainly due to the increase of the number of grain.m⁻² (Orloff et al., 2012; Slafer et al., 2014; Ferrante et al., 2017). Several studies, evaluating the relationship between the responsiveness of yield and different yield components, highlighted a stronger relationship with grain.m⁻² ($R^2=0.75$ in Slafer et al., 2014, R^2 up to 0.98 in Ferrante et al., 2017) on the contrary the grain weight responsiveness is the lowest ($R^2=0.001$ in Slafer et al., 2014). Yield components are influenced by genetic, farmer practices, the environment and the regulations between each other (Orloff et al., 2012; Slafer et al., 2014). According to Figure 2, yield components are not set up at the same time, leading to relations and regulations between Spikes each other (Slafer et al., 2014). Among the yield components, some are more heritable while others are more adaptable to the annual conditions. Grain weight is more heritable, while the number of grain.m⁻² is largely influenced by the environment (water or N stress/availability), leading to large changes in yields (Slafer et al., 2014).

In this context, according to Orloff et al. (2012), N at tillering is critical because it acts on the density of fertile tillers that will later give rise to future spikes. On the contrary, some studies tolerated a deficiency at the beginning of the cycle, suggesting that this will not lead to an impact at harvest (Jeuffroy and Bouchard, 1999). In practice, this led to reduce or eliminate the first application and to shift part of the dose applied at stage Z31 at a later application (Jeuffroy et al., 2013). From such method, NUE aims at increasing as N applications are made later to be more efficiently recovered by the crop (Recous et Machet, 1999). However, this strategy does not have any consensus. Indeed, according to Sylvester-Bradley et al., (1990) and Grindlay et al., (1997) (in Efreteui et al., 2016), N delaying could have a negative effect on yield by reducing the green area (and therefore N accumulation) and could impact grain.m⁻². Efreteui et al. (2016) and Schulz et al. (2015) demonstrated

respectively that the first N application should not be delayed after GS Z30-Z31 and that only one application between GS Z20-Z30 is sufficient.

To date, research on dynamic fertilization management methods include the tolerable deficiencies and are based on a threshold crop N status (Ravier et al., 2017). However, as yield is determined by yield component setup from the early stage and because there is no consensus on splitting fertilization in three-four applications, this work proposes to evaluate the effects of 13 and 20 fertilizations strategies on yield components and N recovery, in two agropedoclimatical situations in 2020 and 2021.

2. Materials and methods

2.1. Experimental sites and fertilization rates

The study was carried out on winter wheat in the North of France (Pas-de-Calais department, 62) during two growing seasons (2019-2020 in Savy and 2020-2021 in Frevillers). Two wheat crop experiments showing various patterns of fertilization strategies were followed, representing different combinations of total N fertilizer levels and splitting strategies. On each site, the experiment was conducted in a randomized block design comprising 13 treatments and six replicates in 2020 and 20 treatments and four replicates in 2021 (Table 1 and 2). In 2020, the trial zone represents 78 microplots of 27.5 m², and in 2021 80 microplots of 26.3 m², implemented in a homogeneous area of a field of 11.2 ha in 2020 and 5.8 ha in 2021. Each treatment represented a fertilization strategy.

Fertilization strategies were compared with two control treatments: an unfertilized control and the Reference Rate (RR) calculated according to the balance sheet method (Comifer et al., 2013). The formula for RR rate calculation is given in Eq. 1 and 2 (Comifer, 2013; Meynard et al., 1997; Beaudoin et al., 2005):

$$RR = (U_2 + N_2 + L + G) - (M + N_1 + U_1 + A) \quad (\text{Eq. 1})$$

Where RR: recommended N dose; U₂ and U₁: N uptake by the crop at harvest and at the end of winter respectively; N₂ and N₁: SMN content at harvest and at the end of winter respectively; A: meteoritic N input; G = gaseous N losses (denitrification and volatilisation); L: N leaching losses during the cropping out of rooting zone; M: net N mineralization by the soil during cropping; all values are in kg N.ha⁻¹.

$$U_2 = b \times Y \quad (\text{Eq. 2})$$

Where Y: objective yield (Mg.ha⁻¹); b: amount of nitrogen absorbed per unit of yield (kg N.Mg⁻¹).

The different used components were either measured (N₁, U₁), estimated from models or from national and regional references (b, N₂, L, G, M, A) or provided directly by farmers (Y). The term U₁ was measured every year in mid-February and Y was the average yield of the given crop for the last 5 harvests. RR correspond to a total amount of 180 kg N.ha⁻¹ in 2020 and 130 kg N.ha⁻¹ in 2021.

Fertilization strategies ranged from 90 kg N.ha⁻¹ (2020_3) to 315 kg N.ha⁻¹ (2020_4) in 2020, and from 50 kg N.ha⁻¹ (R-80) to 300 kg N.ha⁻¹ (2021_14) in 2021. The number of splits ranged from two applications to four for both years. For the two years, according to RR, treatments were made to establish the N response curve. Using the following doses: RR -80 kg N.ha⁻¹, RR -40 kg N.ha⁻¹, RR +40 kg N.ha⁻¹ and RR +80 kg N.ha⁻¹. At harvest, these treatments allowed to determine the optimal N fertilizer rate to maximize performances at harvest while avoiding over-fertilisation, in the agropedoclimatical context considered. This N optimum rate is arbitrarily placed at the onset of the plateau region of the curve.

Some treatments were common to both years studied: 30-30-30 kg N.ha⁻¹ (2020_3 and 2021_11), 60-60-60 kg N.ha⁻¹ (2021_1 and 2021_12) or approximately the same : 105-105-105 kg N.ha⁻¹ (2020_4) and 100-100-100 kg N.ha⁻¹ (2021_14). Part of the treatments received a total amount equal to RR but with different splitting strategies : with high N application at tillering (2020_2, 2020_5, 2021_3, 2021_4), without application at tillering (2020_6 and 2021_5), with early tillering applications (2021_1 and 2021_2), with only two applications (2020_5 and 2021_3) and with four applications where the applied rate didn't exceed 40 kg N.ha⁻¹ (2021_9 and 2021_5). For 2021_6 and 2021_7 the first fertilizer application was made with and addition of Sulfur (N+S) and Phosphorus (N+P) respectively.

For the 2020 season, the Chevignon variety (Saaten Union, 2017, France) was sown after a rapeseed crop, on 24-oct-19. For the 2021 experiment, a varietal mixed was sown on 20-oct-20, by direct sowing after sugar beet. The varietal mixed included Chevignon (Saaten Union, 2017, France), KWS Extase (KWS Momont, 2018, France) and Winner (Florimond Desprez, 2018, France) varieties, in the proportions of one third of each. All N applications were made with 27% ammonium nitrate.

Table 1 : Site location, previous crop, soil mineral N content at 90cm, fertilization gradient and fertilizer reference rates at Savy (2020) and Frevillers (2021) experimental sites

Trial	Location, degrees	Previous crop	Soil mineral N content at 90cm (kg N.ha ⁻¹)	Fertilization gradient (kg N.ha ⁻¹)	Reference dose RR* (kg N.ha ⁻¹)
Savy	50°20'36.2"N 2°33'02.3"E	Rapeseed	91	0-315	180
Frevillers	50°23'41.3"N 2°32'08.5"E	Sugar beet	128	0-300	130

*calculated according to the balance sheet method (Comifer, 2013)

Table 2 : Fertilization strategies in 2020 (a) and 2021 (b): N fertilizer rates in kg N.ha⁻¹, reported per Zadoks growth scale (Zadoks, 1974). The bold line corresponds to the reference dose calculated according to the balance sheet method (Comifer, 2013)

(a) Input in kg.ha ⁻¹	Z29	Z31	Z32	Z39	Total	(b) Input in kg.ha ⁻¹	Z21	Z29	Z31	Z32	Z39	Z59	Total
Control	0	0	0	0	0	Control	0	0	0	0	0	0	0
RR-80	20	60		20	100	RR-80		20	10		20		50
RR-40	40	60		40	140	RR-40		40	30		20		90
(RR)	40	100		40	180	(RR)		40	50		40		130
RR+40	40	100	40	40	220	RR+40		40	50	40	40		170
RR+80	60	100	40	60	260	RR+80		60	50	40	60		210
2020_1	60	60		60	180	2021_1	40		50		40		130
2020_2	80	40		60	180	2021_2	20	40	30		40		130
2020_3	30	30		30	90	2021_3		80	50				130
2020_4	105	105		105	315	2021_4		80	30		20		130
2020_5	80	100			180	2021_5			70		60		130
2020_6		80	40	60	180	2021_6		40+30S	50		40		130
2020_7	40	100		40	180	2021_7		40+40P	50		40		130
						2021_8		40	50		40		130
						2021_9		40	30		40	20	130
						2021_10		40	30		40	20	130
						2021_11		30	30		30		90
						2021_12		60	60		60		180
						2021_13		80	80		80		240
						2021_14		100	100		100		300

S:Sulfur and P:Phosphorus

2.2. Climate data

Normal rainfall (1981-2010) over the study area averages 743mm per year. During the wheat fertilization period (March to June, normal rainfall = 238mm), rainfalls were 24% smaller than the normal in 2020 and 4% higher in 2021. Differences between expected and actual monthly rainfalls quantities are particularly pronounced between May 2020 and 2021 (Figures 3 and 4).




Figure 3: 2020 rainfall in Lille and N application dates (represented by the arrows and the associated stages of application, Z29: 19-march-20, Z31: 1-april-20, Z32: 14-april-20, Z39: 12-may-20)




Figure 4: 2021 rainfall in Lille and N application dates (represented by the arrows and the associated stages of application, Z21 : 25-february-21, Z29 : 11-march-21, Z31 : 6-april-21, Z32 : 28-april-21, Z39 : 27-may-21, Z59 : 3-june-21)

2.3. Crop analysis and ground level measurements

2.3.1. Apparent Nitrogen Recovery (ANR) and Nitrogen Nutrition Index (NNI)

The apparent N recovery (ANR) and the N nutrition index (NNI) were calculated at two Zadoks growth stages per year (Zadoks, 1974). Growing stage Z32 (second node detectable) and Z39 (flag leaf ligule just visible) in 2020, respectively the 23-march-2020 and 6-may-2020. For 2021, Z32 and Z45 (swelling) stages were monitored, the 12-may-2021 and 1-june-2021.

The crops' N concentrations (aerial biomass) were measured to calculate ANR and NNI. Biomass samples were collected in a row of 50 cm in each plot and dried in an oven at 65°C. The aerial biomass per surface unit was calculated using the number of plants and the spacing between rows. After the sample has been finely ground, the N concentration was measured on the aerial part using the Dumas method (NF EN ISO 16634-1). The amount of N uptake by plant was calculated according to (Eq. 3) for a fertilized crop (Tx) and an unfertilized crop (T0).

$$N_{\text{uptake}} \text{ (kg ha}^{-1}\text{)} = \%N \times \text{DM aerial biomass (kg ha}^{-1}\text{)} \quad (\text{Eq. 3})$$

Where, %N was the measured N concentration of the aerial biomass and DM the dry biomass in kg ha⁻¹.

According to these measurements, ANR were calculated with Eq. (4) (Limaux, 1999), for each level of fertilizer accumulation applied. ANR represents the apparent use of fertilizer and is calculated as the difference in N uptake between a fertilized crop (Tx) and an unfertilized crop (T0), relative to the amount of N applied (X).

$$ANR = \frac{T_x - T_0}{X} \quad (\text{Eq. 4})$$

NNI was then calculated using Eq. (5), as the ratio of %N and the critical N concentration (%Nc) for a defined dry biomass (DM). For winter wheat, Nc is obtained using Eq. (6) (Justes et al., 1994).

$$NNI = \%N / \%N_c, \quad (\text{Eq. 5})$$

$$\text{for DM} < 1.55 \text{ T.ha}^{-1} \%N_c = 4.4, \text{ for DM} > 1.55 \text{ T.ha}^{-1} \%N_c = 5.35 * \text{DM}^{-0.442}, \quad (\text{Eq. 6})$$

2.3.2. Yield components

Four yield components: plant and spikes.m⁻², grains.spike⁻¹ and thousand grain weight (TGW) were monitored during crop growth for each treatment (microplot) in three blocks in 2020 and four in 2021. The measurements made for yield components are summarised in Table 3.

Table 3 : yield components monitoring, method and dates of measurement

Method	2020		2021	
	Method	Date	Method	Date
Plants. m⁻²	Measurement made on one row along a length of 50cm	02-april-20	Measurement made on one row along a length of 50cm	1-june-21
Spikes. m⁻²	Measurement made on a soil surface of 0.25m ²	30-june-20	Measurement made on one row along a length of 50cm	23-june-21
Grains.spike⁻¹	Sampling made on one row along a length of 50cm	09-july-20	Sampling made on one row along a length of 50cm	23-june-21

After sampling, grains per spike were counted in laboratory on 10 spikes. According to yield and grains per spike, the TGW were estimated.

Wheat was harvested on 01-august-20 and 16-august-21. Harvest was done with a combine harvester equipped with on-board weighing and moisture measurements. An aliquot of 1 kg grain was then kept per microplot to measure the protein or oil content using an infrared spectroscopy (infralyzer). According to grain moisture, values of yield were corrected to reach 15% moisture content. For each trial, the response of the crop to increasing N inputs (from RR-80 to RR+80) was studied on yield and protein content to determine the optimal N rate to maximize performances at harvest while avoiding overfertilization. The N optimum rate is placed at the onset of the plateau region of the curve when an increase in the dose applied no longer allows an increase in yield.

2.4. Data analysis

Data analyses were done with RStudio (RStudio Team 2019, version 3.6.2).

2.4.1. Study of the effect of fertilization

To evaluate the fertilization effect on yield, protein content, yield component, NNI and ANR, mixed analysis of variance (ANOVA) was performed with blocks as random factor. Tukey's multiple comparison procedure was then applied to compare the means for each fertilization strategy. The goal was to test the following hypothesis: (H_0) there are no differences in terms of yield, protein content, yield component, NNI and ANR between the treatments. A p-value of 0.05 was applied to differentiate the means of the N treatments. Mixed ANOVA and post-hoc tests were made using "nlme" (Pinheiro et al., 2021) and "multcomp" (Hothorn et al., 2008) R packages. The effect of total fertilizer rate and of the N accumulation per application stage were both studied on yield components.

In addition, coefficient of variation was calculated as the ratio of the standard deviation to the mean, for yield, and NNI at stage Z32 (2020-2021), Z39 (2020) and Z45 (2021).

Lastly, a linear regression analysis was done to evaluate the relationship between NNI and the fertilizer amount applied at Z32 and Z39 for Savy and at Z32 and Z45 for Frevillers. Linear regressions were also made between protein content and the total amount applied. The coefficient of determination (R^2 , Eq. 7) of the regression was calculated and the significance of the linear model was determined.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (\text{Eq. 7})$$

2.4.2. Relationships between yield components

The relationships between the yield components were studied by Principal Component Analysis (PCA) and correlation coefficient calculated for the two years. PCA was performed using FactoMineR package (Lê et al., 2008), and the results were visualized thanks to factoextra R package (Kassambara and Mundt, 2016). Correlation coefficients (R) were also calculated between yield components, protein content and yield from correlation matrices made with corrplot package (Wei and Simko, 2021).

3. Results

3.1. Results at harvest

At harvest, yield ranged from 5.25 Mg.ha⁻¹ (Control, 0 kg N.ha⁻¹) to 9.58 Mg.ha⁻¹ (2020_2, 180 kg N.ha⁻¹) in 2020 (Figure 5) and from 3.28 Mg.ha⁻¹ (Control, 0 kg N.ha⁻¹) to 8.91 Mg.ha⁻¹ (2021_4, 130 kg N.ha⁻¹) in 2021 (Figure 6). Yield variations were higher in 2021 than in 2020, as the coefficients of variation were 15% in 2020 and 17% in 2021. The yield obtained by RR was higher in 2020 (8.61 Mg.ha⁻¹) compared to 2021 (7.46 Mg.ha⁻¹). Concerning grain protein content, in 2020, it ranged from 8.3% (Control) to 12% (2020_4, 315 kg N.ha⁻¹), and, in 2021 from 10.2% (R, 130 kg N.ha⁻¹) to 11.7% (2021_14, 300 kg N.ha⁻¹). According to mixed ANOVA, fertilization had a significant effect on yield (p-value<0.001 in 2020 and p-value=0.004 in 2021) and protein content (p-value<0.001 in 2020 and 2021) for both years. The relation between yield and fertilization was higher in 2021 (R²=0.68) than in 2020 (R²=0.42), while the opposite was observed for protein content (R²=0.60 in 2020 and 0.39 in 2021, Figure 7).

In 2020, Control had a significantly lower yield compared to the fertilized modalities (Figure 5). Among fertilized modalities, only RR-80 yield was significantly lower than the best performing modalities: 2020_2 (180 kg N.ha⁻¹), 2020_5 (180 kg N.ha⁻¹) and 2020_4 (315 kg N.ha⁻¹). Except for 2020_4, which received a total amount of fertilizer above the reference, 2020_2 (180 kg N.ha⁻¹) and 2020_5 (180 kg N.ha⁻¹) both received their highest fertilizer application rate at tillering (80 kg N.ha⁻¹).

In 2021, as in 2020, fertilization had significantly improved yields compared to the Control (Figure 6). Except for RR-80 (50 kg N.ha⁻¹), the two other modalities that received less N than the reference; RR-40 (90 kg N.ha⁻¹) and 2021_11 (90 kg N.ha⁻¹) did not perform significantly differently from RR. On the contrary, the best performing modalities are total N fertilizer rate higher than RR; 2021_14 (300 kg N.ha⁻¹), 2021_13 (240 kg N.ha⁻¹), RR+80 (210 kg N.ha⁻¹), 2021_12 (180 kg N.ha⁻¹) and RR+40 (170 kg N.ha⁻¹). Compared to these best-performing modalities, 2021_3 (130 kg N.ha⁻¹) and 2021_4 (130 kg N.ha⁻¹), which are fertilized with the same total dose as the reference, performed equally. If these two modalities had the same total fertilizer rate as RR, they received both a higher input at tillering (80 kg N.ha⁻¹).




Figure 5 : 2020 yield according to fertilization strategies. Boxes present 25-to-75 percentile ranges of yield, the middle line in the boxes is the median and the black points represent the average yield. Each color represents different N fertilization strategies. The modalities grouped under the same letters do not show significant differences according to the Tukey test, p-value threshold of 0.05. RR = 180 kg N.ha⁻¹




Figure 6 : 2021 yield according to fertilization strategies Boxes present 25-to-75 percentile ranges of yield, the middle line in the boxes is the median and the black points represent the average yield. Each color represents different N fertilization strategies. The modalities grouped under the same letters do not show significant differences according to the Tukey test, p-value threshold of 0.05. RR = 130 kg N.ha⁻¹




Figure 7 : Relation between protein content and the total amount of fertilizer at harvest in Frevillers and Savy, dots lines are the linear regressions obtained between protein content and N fertilizer rate, R^2 represents the coefficient of determination of the linear regression. A R^2 with *** is significant at $p < 0.001$ level.




Figure 8 : Response curves of crop yield and protein content to N applications: a) Yield and b) Protein content for 2020 Savy trial, c) Yield and d) Protein content for 2021 Frevillers trial (bars represent standard deviations), RR = 180 kg N.ha⁻¹ in 2020 and 130 kg N.ha⁻¹ in 2021

According to the response curves of crop yield and protein content to increasing N applications (from RR-80 to RR+80), it is possible to determine the optimal N rate maximizing agronomical performances at harvest while avoiding over-fertilization (Figure 8). In 2020, the yield and protein response curves (Figure 8.a and 8.b) highlighted that N optimum rate was achieved for RR+40 modality (220 kg N.ha⁻¹). On the contrary, for 2021 (Figure 8.c), yields continued to increase with N fertilizer rates, without reaching a plateau. Concerning the protein content in 2021 (Figure 8.d), although the curve did not follow the same trend, the best performance was also achieved with RR+80 (210 kg N.ha⁻¹) without reaching the plateau.

3.2. Study of the relationships between yield components and harvest results

To study the relationship between yield and its components, Principal Components Analysis (PCA) were performed for 2020 and 2021 wheat crops.

3.2.1. 2020: Savy

In 2020, the 2 first dimensions resumed 69.9% of the total variability (Figure 9.a). Protein content and number of spikes.m⁻² mainly explained the first axis while the number of plants.m⁻² and TGW were the main contributors to the second axis. Figure 9.a highlights that the most explanatory yield component at harvest was the number of spikes.m⁻² (correlation coefficient, R=0.56). The representation of fertilization strategies as an additive value shows that fertilization mostly explained harvest performances: yield and protein content. On the contrary, N fertilization was poorly linked with TGW and the number of grains.spike⁻¹. TGW was negatively correlated with the number of grains.spike⁻¹ (R=-0.49). Finally, yield and protein contents were positively correlated (R=0.76).

3.2.2. 2021: Frevillers

In 2021 (Figure 9.b), as for 2020, the number of spikes.m⁻² mainly contributed to the first axis while the second axis was mostly explained by TGW. The two first dimensions represented 63% of the total variability (Figure 9.b). Like in 2020, yield and protein content were positively correlated (R²=0.39), while grain weight (TGW) and the number of grains.spike⁻¹ are to a lesser extent negatively correlated (R=-0.51). Unlike 2020, yield appeared to be dependent on the number of plants.m⁻² (R=0.31) and on the number of spikes.m⁻² (R=0.58), however, fertilization mainly influenced harvest performances but also plants.m⁻². In 2021, the number of grains.spike⁻¹ was correlated to the number of spikes.m⁻² (R=0.31).




Figure 9 : PCA graph of variables: yield (Mg.ha⁻¹), protein (protein content %), TGW, plants.m⁻², spike.m⁻², grains. spike⁻¹, a) for 2020 and b) for 2021 (colors correspond to the variable contribution, in dashed blue the total N amount as additive variable)

3.3. Effect of fertilization on yield components

3.3.1. Effect of fertilization strategies

In 2020, fertilization strategies only had a significant effect on the number of spikes.m⁻² (Table 4). Because fertilization had no effect on the number of plants.m⁻², the significant effect of fertilization on spikes.m⁻² was due to the number of spikes.plant⁻¹. Thus, fertilization seemed to have a significant effect on tillering and/or tiller survival process. Spikes.m⁻² ranged from 247 (Control) to 451 (2020_4, 315 kg N.ha⁻¹). According to Tukey’s post-hoc comparisons, the number of spikes for Control was not significantly different between fertilization strategies receiving a total amount of fertilizer strictly lower than RR (RR-80: 100 kg N.ha⁻¹, RR-40: 140 kg N.ha⁻¹, 2020_3: 90 kg N.ha⁻¹) (Table 5).

Table 4 : Summary of the p-values obtained for the mixed ANOVA studying the effect of fertilization strategies on yield components. (Significance of the codes: p-value < 0.001 (***), p-value < 0.01 (**), p-value < 0.05 (*) and p-value > 0.05 (ns))

Yield components	2020	2021
plants.m ⁻²	0.748 (ns)	0.022 (*)
spikes.m ⁻²	1e-04 (***)	4e-04 (***)
grains.spike ⁻¹	0.520 (ns)	0.029 (*)
TGW	0.724 (ns)	0.222 (ns)

Table 5 : 2020 average number of spikes.m⁻² according to fertilization strategies (the modalities grouped under the same letters do not show significant differences according to the Tukey post-hoc test, p-value threshold of 0.05)

Fertilization strategies	Control	RR-80	3	RR-40	RR*	6	1	RR+80	7	2	RR+40	5	4
Spikes.m ⁻²	247	328	341	353	386	389	402	413	415	425	430	446	451
Significant groups	a	ab	ab	ab	b	b	b	b	b	b	b	b	b

*RR= 180 kg N.ha⁻¹

Like in 2020, 2021 fertilization strategies had a high significant effect on the number of spikes.m⁻² (p-value=4e-04). However, unlike 2020, fertilization also influenced the number of plants.m⁻² and the number of grains.spike⁻¹, even if these two last effects were less pronounced than on spikes.m⁻². The number of spikes.m⁻² range from 339 (Control: 0 kg N.ha⁻¹) to 794 (2021_14: 300 kg N.ha⁻¹) (Table 6). The number of spikes.m⁻² for the Control was significantly different for 2021_3, RR+40, 2021_13 and 2021_14, receiving respectively 130 kg N.ha⁻¹, 170 kg N.ha⁻¹, 240 kg N.ha⁻¹ and 300 kg N.ha⁻¹. Except for RR+40 (40 kg N.ha⁻¹), the other mentioned modalities were among the highest inputs at tillering (80 or 100 kg N.ha⁻¹). For 2021_3, the total fertilizer amount (130 kg N.ha⁻¹) was applied at Z29 and Z31, without any application after, during elongation. Concerning, grains.spike⁻¹, it ranged from 35.7 (Control: 0 kg N.ha⁻¹) to 54.8 (2021_12: 180 kg N.ha⁻¹). Plants.m⁻² varied from 205 (RR-80: 50 kg N.ha⁻¹) to 335 (RR : 130 kg N.ha⁻¹), only these 2 modalities were significantly different.

Table 6: 2021 average number of spikes.m⁻² according to fertilization strategies (the modalities grouped under the same letters do not show significant differences according to the Tukey post-hoc test, p-value threshold of 0.05)

Fertilization strategies	Control	9	RR-80	4	10	11	RR*	1	12	8
Spikes.m ⁻²	339	441	459	511	519	519	519	536	571	571
Significant groups	a	ab	ab	abc	abc	abc	abc	abc	abc	abc

Fertilization strategies	RR-40	RR+80	7	6	2	5	3	RR+40	13	14
Spikes.m ⁻²	571	571	586	593	607	621	624	691	720	794
Significant groups	abc	abc	abc	abc	abc	abc	bc	bc	bc	c

*RR= 130 kg N.ha⁻¹

3.3.2. Effect of the fertilization N accumulation per application stage

3.3.2.1. 2020: Savy

In 2020, N applications were made at 4 different stages (Z29, Z31, Z32 and Z39) and the N levels received varied from 7 (Z29) to 9 different doses (Z31 and Z32; Table 2.a). Fertilization practices had a significant effect on spikes.m⁻² from the first application at stage Z29 (Table 7). Tukey's post-hoc comparisons highlighted that cumulative N at tillering strictly higher than 30 kg N.ha⁻¹ had significantly more spikes.m⁻² than the Control. After this stage, all N inputs achieved better performances than the Control for this component. At the last date of application, fertilizer rates higher than 180 kg N.ha⁻¹ were all equivalent to the best modality 2020_4 (315 kg N.ha⁻¹) in terms of spikes.m⁻².

Table 7 : Summary of the p-values obtained for the mixed ANOVA studying the effect of cumulative N fertilization per application on yield components in 2020 (Significance of the codes: p-value < 0.001 (***) , p-value < 0.01 (**), p-value < 0.05 (*) and p-value > 0.05 (ns))

	N levels	Plants.m ⁻²	Spikes.m ⁻²	Grains.spike ⁻¹	TGW
Cumulative N at tillering (Z29)	7 (0 to 105 kg N.ha ⁻¹)	0.57 (ns)	0.0014 (**)	0.78 (ns)	0.60 (ns)
Cumulative N at ear 1cm (Z31)	9 (0 to 210 kg N.ha ⁻¹)	0.28 (ns)	<0.0001 (***)	0.75(ns)	0.65 (ns)
Cumulative N at 2 nodes (Z32)	9 (0 to 210 kg N.ha ⁻¹)	0.30 (ns)	<0.0001 (***)	0.68 (ns)	0.55 (ns)
Cumulative N at last leaf spread (Z39)	8 (0 to 315 kg N.ha ⁻¹)	0.20 (ns)	<0.0001 (***)	0.55 (ns)	0.43 (ns)

3.3.2.2. 2021: Frevillers

In 2021, depending on each fertilization strategy, N was brought at 6 different crop stages (Z21, Z29, Z31, Z32, Z39, Z59; Table 2.b). N levels varied from 3 (Z21: early tillering) to 11 different doses (Z32) (Table 8). N application at early tillering had no effect on yield components. N fertilization had a significant effect on the number of spikes.m⁻² and grains.spike⁻¹ from tillering stage. The fertilization effect is more pronounced for spikes.m⁻² than for grains.spike⁻¹. This is consistent with 2020 results, where the number of spikes.m⁻² were largely influenced by N fertilization. For the number of spikes.m⁻², at tillering, according to Tukey's post-hoc comparisons, cumulative N inputs lower and equal to 60 kg N.ha⁻¹ did not perform better than unfertilized control, only 80 kg N.ha⁻¹ and 100 kg N.ha⁻¹ led to a significantly higher number of spikes.m⁻². At the last date of application, fertilizer rates higher than 170

kg N.ha⁻¹ were all equivalent to the best modality 2021_14 (300 kg N.ha⁻¹). The number of plants.m⁻² is affected by fertilization from Z31 stage.

Table 8 : Summary of the p-values obtained for the mixed ANOVA studying the effect of cumulative N fertilization per application on yield components in 2021 (Significance of the codes: p-value < 0.001 (***), p-value < 0.01 (**), p-value < 0.05 (*) and p-value > 0.05 (ns))

	N levels	Plants.m ⁻²	Spikes.m ⁻²	Grains.spike ⁻¹	TGW
Cumulative N at early tillering (Z21)	3 (0 to 105 kgN.ha ⁻¹)	0.99 (ns)	0.79 (ns)	0.19 (ns)	0.99 (ns)
Cumulative N at tillering (Z29)	7 (0 to 105 kgN.ha ⁻¹)	0.091 (ns)	0.0043 (**)	0.021 (*)	0.54 (ns)
Cumulative N at ear 1cm (Z31)	10 (0 to 105 kgN.ha ⁻¹)	0.044 (*)	<0.0001 (***)	0.0020 (**)	0.60 (ns)
Cumulative N at 2 nodes (Z32)	11 (0 to 105 kgN.ha ⁻¹)	0.039 (*)	<0.0001 (***)	0.0055 (**)	0.68 (ns)
Cumulative N at last leaf spread (Z39)	10 (0 to 105 kgN.ha ⁻¹)	0.029 (*)	<0.0001 (***)	0.020 (*)	0.039 (*)
Cumulative N at heading (Z59)	9 (0 to 105 kgN.ha ⁻¹)	0.014 (*)	<0.0001 (***)	0.0025 (**)	0.60 (ns)

3.4. NNI dynamics in 2020 and 2021

In 2020, measured NNI values ranged from 0.42 (Control - Z32) to 1.4 (RR+40 - Z39) (Figure 10). Even if at stage Z32 average NNI were lower than one, at stage Z45 only five treatments were lower than this threshold value, i.e. treatments with a total N fertilizer amount lower than RR and 2020_6. On average, all fertilized modalities had a NNI greater than 0.7, the threshold NNI defined by Ravier et al. (2017) at stages Z32 and Z39. In 2021, NNI levels were lower and varied from 0.36 (Control-Z45) to 1.02 (2021_14-Z45), and most of the NNI values were lower than one. At stage Z45, treatments RR+80, RR+40, 2021_3, 2021_4, 2021_6, 2021_13 and 2021_14 have allowed to exceed the threshold of 0.7. For all measurement dates, fertilization practices had a significant effect on NNI (p-value<0.05). Between the 2 sites, at stage Z32, the differences in NNI were more pronounced in Frevillers than in Savy; coefficients of variation were 27% and 15% respectively. The opposite was observed between Z39 and Z45 where the coefficient of variation was 29% for Savy and 27% for Frevillers. According to Figure 11, fertilization had a higher effect in 2020 than in 2021. For both years the N level was positively correlated with NNI according to a linear model, this correlation was observed for 2020 and 2021 early in season from the stage Z32 (R²=0.52 in 2020 and R²=0.56 in 2021).




Figure 10 : Average NNI per modality according to stage studied for Savy 2020 (a) and Frevillers 2021 (b) (bars represent standard deviations), the horizontal line represents NNI=1 which is the critical INN according to Justes et al. 1994, the dashed horizontal line represents the optimal NNI path with non detrimental N deficiencies for stage Z32 and Z39 (INN=0.7) according to Ravier et al. 2017, RR= 180 kg N.ha⁻¹ in 2020 and 130 kg N.ha⁻¹ in 2021

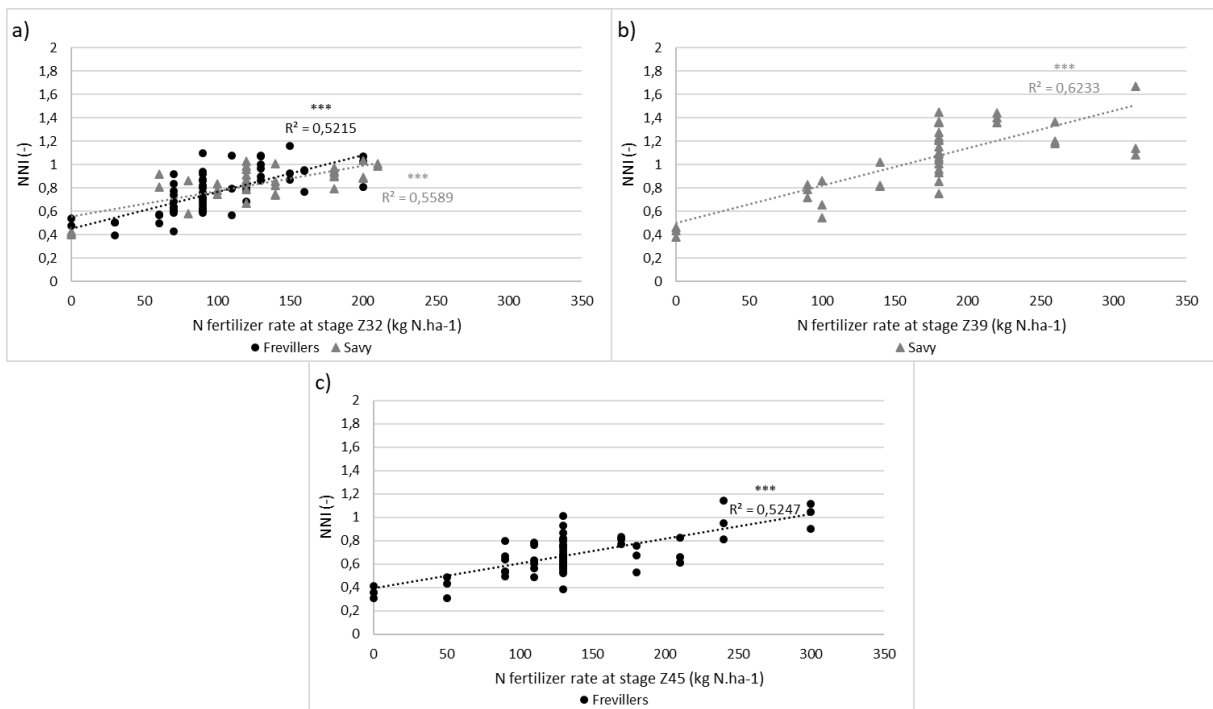


Figure 11 : Relation between NNI and total amount of fertilizer at stage Z32 (a), Z39 in Savy (b) and Z45 in Frevillers (c). Dotted lines are the linear regressions obtained between NNI and N fertilizer rate, R² represents the coefficient of determination of the linear regression. A R² with *** is significant at p < 0.001 level.

3.5. ANR evolution according to fertilization strategies

3.5.1. 2020: Savy

The apparent use of fertilizer (ANR) was studied at Z32 and Z39 for each fertilization strategy in 2020 (Figure 12). At Z32, average ANR ranged from 21% (RR+80) to 79% (2020_3), which corresponds respectively to the highest (200 kg N.ha⁻¹) and the lowest (60 kg N.ha⁻¹) cumulative N input at stage Z32. A trend emerges, that ANR decreases as the cumulative N inputs increases (Figure 14.a), with a significant effect of fertilization (p-value=0.008). Only 2020_3 is significantly different from the reference. At Z39, in average, ANR levels were higher than at the beginning of elongation, 54.2% on average vs. 40.1% at Z32. At this stage, ANR ranged from 36% (RR-80) to 79% (2020_5). For 2020_5, N applications are made early in the season as the total amount of fertilizer was applied at Z31 (180 kg N.ha⁻¹). However, at this stage, fertilization did not have a significant effect (p-value=0.55).

3.5.2. 2021: Fréwillers

In 2021, at stage Z32, ANR ranged from 25% (2021_11) to 93% (RR-40) (Figure 13). The lowest ANR (2021_11: 60 kg.ha⁻¹) was obtained for the same fertilization strategy as the modality with the best ANR in 2020 at the same stage (2020_3). As observed in 2020, ANR levels were higher at the second stage where it reached 120% at Z45 (2021_4). The ANR increased at the end of elongation was more pronounced in 2021 than in 2020 which is consistent with the response curve where the plateau was not reached (Figure 7). However, in 2021, fertilization did not have any significant effect on ANR for both studied stages (p-value=0.70 at Z32 and 0.55 at Z39) (Figure 14.b).

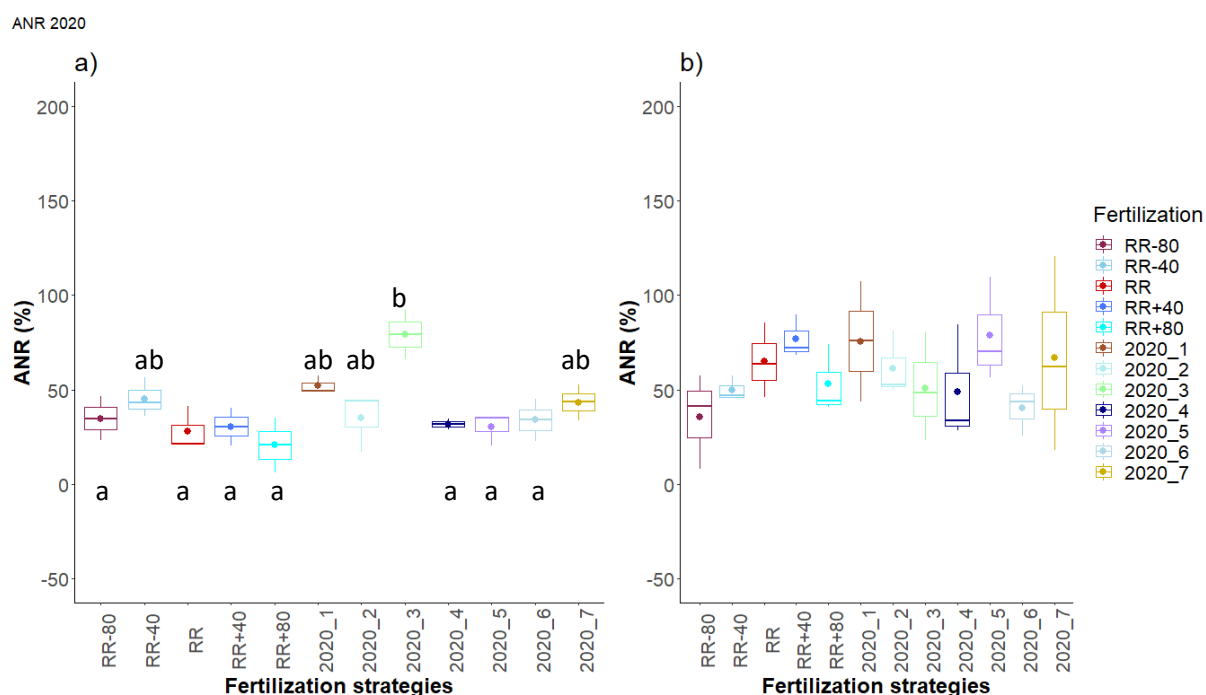


Figure 12 : ANR according to fertilization strategies at stage Z32 (a) and Z39 (b) for 2020 trial. Boxes present 25-to-75 percentile ranges of ANR, the middle line in the boxes is the median and the points represent the average ANR. Each color represents different N fertilization strategies, and letters are results of Tukey's post-hoc test for means comparison (p<0.05). Means with the same letters are not significantly different. Without letters there is no significant effect of fertilization. RR= 180 kg N.ha⁻¹ in 2020




Figure 13 : ANR according to fertilization strategies at stage Z32 (a) and Z39 (b) for 2021 trial. Boxes present 25-to-75 percentile ranges of ANR, the middle line in the boxes is the median and the points represent the average ANR. Each color represents different N fertilization strategies. There is no significant effect of fertilization. RR=130 kg N.ha⁻¹ in 2021

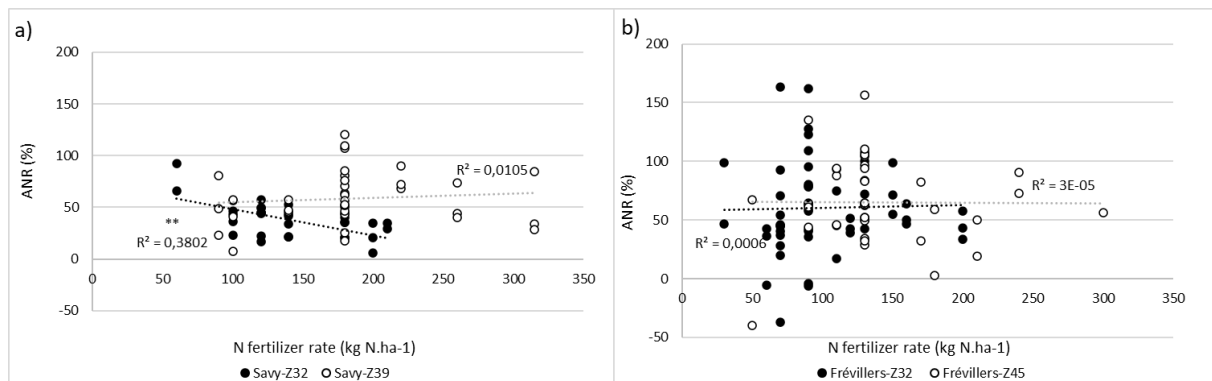


Figure 14 : ANR according to fertilizer amount applied at stage Z32 and Z39 in Savy (a) and Z32 and Z45 in Fréville (b). Dotted lines are the linear regressions obtained between ANR and N fertilizer rate, R² represents the coefficient of determination of the linear regression. According to mixed Anova, a significant relation was observed only for Savy at stage Z32 (R² with ** is significant at p < 0.01 level)

4. Discussion

4.1. Results at harvest

Due to differences in the crop contexts (variety, previous crop, sowing, etc.) and to annual growth conditions (dry year in 2020 and wet in 2021), at harvest, yield and protein content were not impacted by fertilization in the same way for the 2 years considered. Yield was higher in 2020 than in 2021, as it can be illustrated by comparing the yields obtained for the reference rate (RR): 8.61 Mg.ha⁻¹ in 2020 and 7.46 Mg.ha⁻¹ in 2021. The same trend was observed for protein content (10.8 in 2020 and 10.2 in 2021 for RR). The protein content increased with the fertilizer rate, particularly in Savy (R²=0.60 and

0.39 in Frevillers), even if, according to the response curve, the best fertilizer rate was 220 kg N.ha⁻¹ (RR+40) in 2020. However, in 2021, crop response to fertilization was different, as illustrated by the response curve that did not reach the plateau. This result is consistent with the NNI path in 2021, as NNI were mostly (except for 2021_14, 300 kg N.ha⁻¹) below the threshold of one, which indicates a N deficiency. In this limiting context, the consideration of all modalities highlights that fertilization strategies higher than the reference resulted in the highest yields.

Finally, according to PCA results, protein content and yield seemed to be positively correlated for the two studied years. Orloff et al. (2012) highlighted that, although there is an unavoidable negative relationship between yield and protein content, in practice it is possible to improve yield and quality at harvest through suitable fertilization management.

4.2. Yield components

Among the studied yield components (spikes.m⁻², plants.m⁻², grains.spike⁻¹, grain weight according to TGW), a general trend emerges between 2020 and 2021 concerning spikes.m⁻² and TGW, however concerning plants.m⁻² and grains.spike⁻¹ no clear relationship was found between the 2 years studied.

4.2.1. Plant.m⁻² and grains.spike⁻¹: different relations for the 2 years

The different trends concerning plant.m⁻² and grains.spike⁻¹ can be explained by genetic, environment or compensation effect between yield components (Slafer et al., 2014). Unlike in 2020, in 2021 the number of plants.m⁻² was related to yield in 2021, the sowing could be an explanation. Indeed, in 2021, the crop was sown by direct sowing after sugarbeet in wet sowing conditions, which led to unfavourable conditions for the crops' emergence (Labreuche et al., 2013). In October 2020, monthly rainfalls reached 109mm, while the average for 1981 to 2010 was 66mm. These limiting conditions on the number of plants.m⁻² can also explain why this component was correlated to harvest performance.

The effect of fertilization on the number of grains.spike⁻¹ varied according to the site and studied year: no effect in 2020 (p-value=0.52) and a significant effect in 2021 (p-value=0.030). The studies presenting the effect of fertilization on the number of grains.spike⁻¹ had also contrasted results. Brucker and Morey (1988), Ali et al. (2011), Hussain et al. (2006) highlighted the number of grains.spike⁻¹ increases with the N fertilizer rates. However, Brucker and Morey (1988), Hussain et al. (2006) and Mandic et al., (2015) didn't observe any significant effect of fertilization and mentioned that the variety, and thus genetic, can also interfere. According to Slafer et al. (2014) the number of grains.spike⁻¹ depends on spikes.m⁻² by feedback control and is more regulated by genotype.

4.2.2. Spikes.m⁻² and TGW: general trend for the 2 years

The number of spikes.m⁻² was a determining yield component for both 2020 and 2021 (with respective correlation coefficients of R=0.56 and R=0.58). This result is consistent with Slafer et al. (2014), Orloff et al. (2012), Ferrante et al. (2017), as grains and spikes numbers are usually strongly associated with yield. On the contrary, as demonstrated by other studies (Slafer, 2003; Fisher, 2007 in Slafer et al., nd; Slafer et al., 2014), TGW had no effect on performances at harvest for the two studied years. In their study on wheat, Slafer et al. (2014) obtained a high correlation between yield responsiveness and grains.m⁻² (R²=0.75) while the correlation was poor with grain weight (R²=0.01). Because crops firstly produce the grains before filling them, TGW is dependent on other yield components, by compensation effect (Slafer et al., 2014). This could explain the negative relationship observed between TGW and grains.spike⁻¹ (R=-0.38 in 2020 and R=-0.51 in 2021). In addition, fertilization had a strong significant effect on spikes.m⁻² (p-value=1e-04 in 2020, and 4e-04 in 2021). Thus, as the number of spikes.m⁻² is the main yield determinant, studying this component according to the different fertilization strategies seemed to be relevant.

4.3. Effect of fertilization on spikes.m⁻²

According to Slafer et al. (2014), the grain number per m² is mostly able to accommodate to large changes in the environment (water or N stress/availability) leading to large changes in yields. Thus, because grains.m⁻² is determined by spikes.m⁻² (Salfer et al., nd), this explains the significant fertilization effect on spikes.m⁻² highlighted for the 2 studied years (p-value=1e-04 in 2020, and 4e-04 in 2021). This effect occurred from tillering. At this stage, fertilizer rate strictly higher than 30 kg N.ha⁻¹ had significantly more spikes.m⁻² than the Control in 2020. This threshold rate increased to 60 kg N.ha⁻¹ in 2021. Thus, as spikes.m⁻² is the most yield determinant, N availability at early stage seemed to be important to support tillering and tiller survival. In this context, according to Orloff et al. (2012) an adequate N supply during the vegetative growth is critical to reach potential yield. For the 2 considered trials, the results confirm that high fertilizer rates at tillering allowed to achieve the highest yields, for total N fertilizer rates equivalent to the reference dose. Indeed, in 2020, the best performing modalities (2020_2 and 2020_5) received a total of 180 kg N.ha⁻¹, equivalent to the reference dose. However, they had the particularity of benefiting from high input rates just at the end of winter, respectively 120 and 180 kg N.ha⁻¹ at Z31, which represented 67% and 100% of the total fertilizer amount. The importance of fertilization at tillering was confirmed in 2021 because, at harvest, two modalities (2021_3 and 2021_4) fertilized as the reference performed as well as strategies with a total amount higher than the reference. These two modalities had the highest rate at tillering and received respectively 130 and 110 kg N.ha⁻¹ at Z31, which represented 100% (2021_3) and 85% (2021_4) of their total fertilizer amount. Thus, although yield response differed between the 2 years, when the N fertilizer rate increases, the high input strategies at tillering were efficient for the 2 trials considered.

4.4. NNI and fertilization strategies

However, in literature, the fertilization strategy at these stages (Z29 and Z31), was widely criticized. According to Jeuffroy and Bouchard (1999), a deficiency at the beginning of spring is not detrimental for yield if, in the month before flowering, the nutrition level is not limiting. In this context, new acceptable NNI trajectories have been defined for fertilization management, to include tolerable deficiencies from tillering to flowering. Instead of aiming for a NNI equal to one (Justes et al., 1994), the new target NNI varies according to the crop stage: a value of 0.4 at Z31, 0.7 at Z32 and Z39 and 0.9 at Z65 stages (Ravier et al., 2017). To follow these trajectories, it is advisable to reduce or eliminate the first application and to shift part of the dose later to ears 1 cm (Jeuffroy et al., 2013). Because the first N fertilizer application are less recovered by the crop than later applications (Limaux, 1999; Sieling and Kage, 2021) this strategy should enable to increase N recovery and aims to reduce N pollutions (Jeuffroy et al., 2013). However, in our context, this strategy doesn't seem to be relevant as for both years, strategies with high fertilizer rate at tillering are among the most efficient at harvest. In addition, by comparison with NNI optimal threshold path with tolerable deficiency, in our case, even if all the fertilized modalities have reached this threshold value (0.7 at Z32) in 2020 at stage Z39, it was not the case in 2021. Indeed, at Z45, only modalities with a total amount higher than RR (RR+40, RR+80, 2021_13, 2021_14) or with a high N fertilizer rate applied at Z29 (2021_3 and 2021_4) have allowed to reach this NNI. These results raise questions about the potential of adaptation of this threshold NNI path to different pedoclimatic contexts.

As spike number are strongly associated with yield and because fertilization practices have a significant effect on this component, that explains the importance of fertilization from tillering highlighted in this context. To complement these observations, the study made on the N inputs valuation is important.

4.5. Apparent N recovery (ANR)

It is known that ANR at beginning of spring is smaller than for later applications (Sieling and Kage, 2021; Limaux et al., 1999; Machet et al., 1987). Sieling and Kage (2021) found ANR ranging from 42% to 62% at beginning of spring, and from 44% to 82% at ear emergence. In 2020, ANR obtained were quite low: 40.1% at Z32 and 54.2% at Z39 on average. In 2021, average ANR were 57.1% at Z32 and 65.1% at Z39. As ANR depends on the growth rate of the crop at the time of N application (Limaux, 1999), this explains the differences between Z32 and Z39 values.

Fertilization had only a significant effect on ANR in 2020 at stage Z32, which highlights the influence of other parameters such as meteorological conditions, soil tillage and sowing conditions. The higher ANR levels in 2021 than 2020 can be explained by the environment. Indeed, as highlighted by Ferrante et al. (2017), N fertilization effect vary according to environmental conditions. Some studies highlighted the importance of rain during a short period just after N applications (Bouthier, 1997 in Cohan et al., 2018). In 2020, the conditions were particularly dry after the two first applications (Z29 and Z31, Fig 3) and there were only 4.2 mm of rain during May around the Z39 application. This can explain the low ANR of this year compared to 2021 and why higher is the fertilizer rate applied, lower is the ANR. Some studies have evaluated the consequences of soil tillage on N recovery, Ruissi et al. (2016) highlighted that no-tillage was associated with less N uptake by wheat, mainly attributable to a decrease in soil N availability, and to a lesser extent, to a decrease in the N fertilizer recovery. On the contrary Habbib et al. (2017) showed that no-tillage increases ANR. The effect of tillage on ANR vary according to the studies, even if they highlighted that other agricultural practices (cover crop, rotation, etc) can also impact ANR (Ruissi et al., 2016; Habbib et al., 2017). In case of this study with direct sowing after rapeseed in 2021, it is difficult to have an explanation on the effect of no tillage on N recovery as we cannot compare our results with conventional tillage. However, as mentioned before, the wheat was sown by direct sowing after sugar beet in dry conditions, which led to unfavourable conditions for the development of the crop with probably poor root exploration. This hypothesis is consistent with the small NNI, lower than one, in most cases, which indicates that N was a limiting factor for crop growth. In this context, the conditions were probably not favourable for soil N uptake as the root exploration is limited which conduct to increase N fertiliser uptake and ANR. In addition, harvesting sugar beets in wet conditions may also have led to heterogeneous soils conditions, explaining the large variations in ANR observed for a same treatment.

At Z32 in 2020, ANR decreased when the fertilizer rate increased. At this stage, 2020_3 (60 kg N.ha⁻¹ at Z32) had the highest ANR (79%) and was significantly different from ANR obtained for application higher or equal to 140 kg N.ha⁻¹, except for 2020_7. Although there were no significant differences between fertilized modalities, at Z39, ANR ranged from 36% (R-80) to 79% (2020_5). The best ANR was achieved for the modality with the second highest yield and with the total amount of N fertilizer was applied at stage Z31. In 2021, no significant relations could be established between ANR and fertilization strategies. At Z32, ANR ranged from 25% (2021_11) to 93% (R-40), the lowest ANR was obtained for a fertilizer rate equivalent to the best strategy the previous year (60 kg N.ha⁻¹, 2020_3), which confirms the influence of other factors than fertilization on ANR. A stage Z45, ANR ranged from 45% (2021_12) to 120% (2021_4). Like in 2020, the best ANR was obtained for modality with 80 kg N.ha⁻¹ applied at tillering, although there is no significant effect of fertilization. In some cases, ANR were greater than 100%. Among the 74 trials monitored by Limaux (1999), this occurred in 7% of the cases. This is explained as ANR is only the “apparent” N utilization. N application changed the real contribution of soil N by comparison to the unfertilized control, thus N derived from soil is often higher in fertilized modalities than without fertilizer applications (Limaux, 1999).

Thus, in these trials condition, it was difficult to conclude on the effect of fertilization on N recovery as fertilization had a significant effect only at Z32 stage in 2020. Indeed, in 2020 at stage Z32 high fertilizer rate had a negative effect on ANR, while later in season, at Z39 the differences in the doses applied did not lead to a significant change in ANR. In 2021, for both studied stages, reducing the applied N fertilizer rate has not led to an improvement in the N recovery. These results highlight the importance of monitoring crop N status during crop growth to synchronize N application with crop N requirements and in optimal N recovery conditions.

5. Conclusion

This work aimed at (i) studying yield and yield components and (ii) comparing harvest performance and ANR for a wheat crop receiving different fertilizations strategies, for 2 different agropedoclimatical situations. Among studied yield components (spikes.m⁻², plants.m⁻², grains.spike⁻¹, grain weight according to TGW), the number of spikes. m⁻² was the main yield determinant. For both studied years, fertilization practices had a significant effect on this component, from the tillering stage and with significant impact on harvest performances. Indeed, even if yield response differed between the 2 years studied when the N fertilizer rate increased, the high input strategy at tillering was efficient to improve yield at harvest for the 2 trials considered and for total N fertilizer rates equivalent to the reference dose. In this context, N supply at the end of winter was critical to reach the crop's potential yield by supporting tillering and tiller survival. This brings into question the NNI curve with tolerable deficiencies at the beginning of the cycle which was not relevant in this case. However, even if some trends emerge, several observations were not shared between the 2 trials studied. As demonstrated in other studies, the fertilization effect varies depending on the environmental conditions, which allows only partial conclusions as just two trials are considered. The contrasting weather and sowing conditions highly influenced crop growth and N fertilization recovery. Indeed, fertilization strategies did not lead to a significant change in final N recovery in 2020 and 2021. Thus, in this context, decreasing the applied N fertilizer rate has not led to an improvement in the N recovery. These results highlight the importance of monitoring crop N status during crop growth to improve N recovery conditions consideration and synchronize N application with crop N requirements. Finally, more trials are needed to confirm the interest in high N applications at tillering stage and evaluate the environmental risk of early inputs. Because N recovery increased at later stages, more study should help to find a compromise between productivity and ANR increase.

References:

- Ali A., Ahmad A., Syed W.H., Khaliq T., Asif M., Aziz M., 2011. Effects of nitrogen on growth and yield components of wheat (report). *Science International (Lahore)* 24, pp. 331-332.
- Beaudoin N., Saad J.K., Van Laethem C., Machet J.M., Maucorps J., Mary B., 2005. Nitrate leaching in intensive agriculture in Northern France: Effect of farming practices, soils and crop rotations. *Agriculture, Ecosystems and Environment*, 111, pp. 292-310. doi.org/10.1016/j.agee.2005.06.006.
- Brown B., Westcott M., Christensen N., Pan B., Stark J., 2005. Nitrogen management for hard wheat protein enhancement. PNW 578.
- Brucker, P. L., & Morey, D. D., 1988. Nitrogen effects on soft red winter wheat yield, agronomic characteristics, and quality. *Crop science*, 28(1), pp. 152-157. doi.org/10.2135/cropsci1988.0011183X002800010033x.
- Cohan J.P., Soenen B., Le Souder C., Vericel G., Laurent F., 2018. Improving nitrogen use efficiency in wheat: recent progress and prospects in France. In : Phloème 2018, Paris, France.
- COMIFER, 2013. Calcul de la fertilisation azotée. guide méthodologique pour l'établissement des prescriptions locales. Cultures annuelles et prairies. Available online: http://www.comifer.asso.fr/images/publications/brochures/BROCHURE_AZOTE_20130705eb.pdf (last accessed 08/04/2021)
- Cossani C.M., Slafer G.A., Savin R., 2012. Nitrogen and water use efficiencies of wheat and barley under a Mediterranean environment in Catalonia. *Field Crops Research*, 128, pp. 109–118. doi.org/10.1016/j.fcr.2012.01.001.
- de Oliveira Silva A., Ciampitti I.A., Slafer G.A., Lollato R.P., 2020. Nitrogen utilization efficiency in wheat: A global perspective. *European Journal of Agronomy*, 114. doi.org/10.1016/j.eja.2020.126008.
- Degan F. Enquête nationale “fertilisation azotée”: des pratiques plus performantes et efficaces. 2019. *Perspectives agricoles*, 463.
- Efretuei A., Gooding M., White E., Spink J., Hackett R., 2016. Effect of nitrogen fertilizer application timing on nitrogen use efficiency and grain yield of winter wheat in Ireland. *Irish Journal of Agricultural and Food Research*, 55(1). doi.org/10.1515/ijafr-2016-0006.
- Ferrante A., Cartelle J., Savin R., Slafer G., 2017. Yield determination, interplay between major components and yield stability in a traditional and a contemporary wheat across a wide range of environments. *Field Crops Research*, 203, pp. 114-127. doi.org/10.1016/j.fcr.2016.12.028.
- Habbib H., Bertrand H., Julien V., David R., Lacoux J., Lea P., Dubois F., Tétu T., 2017. Investigating the combined effect of tillage, nitrogen fertilization and cover crops on nitrogen use efficiency in winter wheat. *Agronomy*, 7, 66. doi.org/10.3390/agronomy7040066.
- Hirel B., Le Gouis J., Ney B., Gallais A., 2007. The challenge of improving nitrogen use efficiency in crop plants: towards a more central role for genetic variability and quantitative genetics within

- integrated approaches. *Journal of Experimental Botany*, 58, pp. 2369–2387. doi.org/10.1093/jxb/erm097.
- Hothorn T, Bretz F, Westfall P., 2008. Simultaneous Inference in General Parametric Models. *Biometrical Journal*, 50(3), pp. 346–363.
- Hussain I., Khan M.A., Khan E.A., 2006. Bread wheat varieties as influenced by different nitrogen levels. *Journal of Zhejiang Univ. - Sci. B* 7, pp. 70–78. doi.org/10.1631/jzus.2006.B0070.
- Jeuffroy M.-H., Bouchard C., 1999. Intensity and duration of nitrogen deficiency on wheat grain number. *Crop Science*, 39, pp. 1385-1393.
- Jeuffroy M.H., Gate P., Machet J.M., Recous S., 2013. Gestion de l'azote en grandes cultures : les connaissances et outils disponibles permettent-ils de concilier exigences agronomiques et environnementales ? *Cahiers Agricultures*, 22. doi.org/10.1684/agr.2013.0639.
- Justes, E., Mary, B., Meynard J-M., Machet J-M., Huché-Théliér L., 1994. Determination of a critical nitrogen dilution curve for winter wheat crops. *Annals of Botany*, 74, pp. 397-407. doi.org/10.1006/anbo.1994.1133.
- Kassambara A., Mundt F., 2016. factextra : extract and visualize the results of multivariate data analyses.
- Labreuche J., Bureau S., de Bateir H., Duval R., 2013. Une rotation betteravière propice au labour et au semis direct. *Perspectives Agricoles*, 403, pp. 36-40.
- Lê S., Josse J., Husson, F., 2008. FactoMineR: An R package for multivariate analysis. *Journal of Statistical Software*, 25(1), pp. 1-18.
- Lemaire G., 2019. Une nouvelle approche de la fertilisation des cultures. *Agronomie, Environnement et Sociétés*, Association Française d’Agronomie (Afa), 9.
- Limaux F. Modélisation des besoins du blé en azote, de la fourniture du sol et de l’utilisation de l’engrais : application au raisonnement de la fertilization en Lorraine. *Sciences agricoles*. Institut National Polytechnique de Lorraine, 1999. Français.
- Limaux F., Recous S., Meynard J.-M., Guckert A., 1999. Relationship between rate of crop growth at date of fertiliser N application and fate of fertiliser N applied to winter wheat. *Plant Soil*, 214, pp. 49–59. doi.org/10.1023/A:1004629511235.
- Machet J.M., Pierre D., Recous S., Remy J.C., 1987. Signification du coefficient reel d'utilisation et consequences pour la fertilisation azotée des cultures.. *Comptes Rendus de l'Académie d'Agriculture de France*, 73 (3), pp.39-55.
- Mandić V., Krnjaja V., Tomic Z., Bijelić Z., Simic A., Muslic D., Gogić M., 2015. Nitrogen fertilizer influence on wheat yield and use efficiency under different environmental conditions. *Chilean journal of agricultural research*, 75, pp. 92-97. doi.org/10.4067/S0718 58392015000100013.
- Masclaux-Daubresse C., Daniel-Vedele F., Dechorgnat J., Chardon F., Gaufichon L., Suzuki A., 2010. Nitrogen uptake, assimilation and remobilization in plants: challenges for sustainable and productive agriculture. *Annals of Botany*, 105, pp. 1141-1157. doi.org/10.1093/aob/mcq028.
- Meynard J.M., Jeuffroy M.H., 2019. 50 ans de méthode du Bilan : progrès passés et limites actuelles. *Agronomie, Environnement et Sociétés*, 9(1), pp. 45-54.

- Meynard J.M., Justes E., Machet J.M., Recous S., 1997. Fertilization azotée des cultures annuelles de plein champ. In: Lemaire, G., Nicolardot, B. (Eds.), *Maîtrise de l'azote dans les agrosystèmes*. INRA Editions, Paris, pp. 183–200.
- Moll R.H., Kamprath E.J., Jackson W.A., 1982. Analysis and interpretation of factors which contribute to efficiency of nitrogen utilization. *Agronomy Journal* 74, pp. 562–564. doi.org/10.2134/agronj1982.00021962007400030037x.
- Orloff S., Wright S., Ottman M., 2012. Nitrogen management impacts on wheat yield and protein. In : *Proceedings of California Alfalfa & Grains Symposium*, Sacramento, CA.
- Pinheiro J, Bates D, DebRoy S, Sarkar D, R Core Team, 2021. nlme: Linear and Nonlinear Mixed Effects Models. R package version 3.1-153. Available online: <https://CRAN.R-project.org/package=nlme>. (last accessed on 26/01/2022)
- Ravier C., Jeuffroy M.H., Gate P., Cohan P., Meynard J.M., 2018. Combining user involvement with innovative design to develop a radical new method for managing N fertilization. *Nutrient Cycling in Agroecosystems*, 110(4), pp. 117–134. doi.org/10.1007/s10705-017-9891-5.
- Ravier C., Jeuffroy M.H., Meynard J.M., 2016. Mismatch between a science-based decision tool and its use: The case of the balance-sheet method for nitrogen fertilization in France. *NJAS Wageningen Journal of Life Sciences*, 79. doi.org/10.1016/j.njas.2016.10.001.
- Ravier C., Meynard J.M., Cohan J.P., Gate P., Jeuffroy M.H., 2017. Early nitrogen deficiencies favor high yield, grain protein content and N use efficiency in wheat. *European Journal of Agronomy*, 89, pp. 16-24. doi.org/10.1016/j.eja.2017.06.002
- Recous S., Machet J.M., 1999. Short-term immobilisation and crop uptake of fertiliser nitrogen applied to winter wheat : effect of date of application in spring. *Plant Soil*, 206, pp. 137-149.
- Ruisi P., Saia S., Badagliacca G., Amato G., Frenda A.S., Giambalvo D., Di Miceli G., 2016. Long-term effects of no tillage treatment on soil N availability, N uptake, and 15N-fertilizer recovery of durum wheat differ in relation to crop sequence. *Field Crop. Res.*, 189, pp. 51–58. doi.org/10.1016/j.fcr.2016.02.009.
- Schulz R., Makary T., Hubert S., Grubera S., Donath S., Döhler J., Weiss K., Ehrhart E., Claupein W., Piepho H.P., Pekrun C., Müller T., 2015. Is it necessary to split nitrogen fertilization for winter wheat? On-farm research on Luvisols in South-West Germany. *Journal of Agricultural Science*, 153, pp. 575–587. doi.org/10.1017/S0021859614000288.
- Sharma L.K., Bali S.K., 2018. A review of methods to improve nitrogen use efficiency in agriculture. *Sustainability* 10 (51). doi.org/10.3390/su10010051.
- Sieling K., Kage H., 2021. Apparent fertilizer N recovery and the relationship between grain yield and grain protein concentration of different winter wheat varieties in a long-term field trial. *European Journal of Agronomy*, 124, 126246. doi.org/10.1016/j.eja.2021.126246.
- Slafer G.A., Sadras V.O., Savin R., no date. Is compensation between yield components in wheat a feedback process of responses to availability of resources?
- Slafer G.A., Savin R., Sadras V.O., 2014. Coarse and fine regulation of wheat yield components in response to genotype and environment. *Field Crops Research*, 157, pp. 71-83. doi.org/10.1016/j.fcr.2013.12.004.

- Sylvester-Bradley R., Kindred D.R., 2009. Analysing nitrogen responses of cereals to prioritize routes to the improvement of nitrogen use efficiency. *Journal of Experimental Botany*, 60(7), pp. 1939–1951. doi.org/10.1093/jxb/erp116.
- Wei T., Simko V. 2021. R package 'corrplot': Visualization of a Correlation Matrix. (Version 0.92). Available online: <https://github.com/taiyun/corrplot> (last accessed on 26/01/2022)
- Zadoks J.C., Chang T., Konzak C.F., 1974. A decimal code for the growth stages of cereals. *Weed Research*, 14, pp. 415-42.

Chapitre V

Evaluation des performances agroenvironnementales d'outils d'aide à
la décision en fertilisation azotée

Les quatre premiers chapitres de ce manuscrit ont porté sur le suivi du statut azoté du blé en cours de croissance par proxi- et télédétection. La démarche présentée a permis d'identifier les leviers et les limites de ces méthodes et a conduit à mettre en évidence le potentiel qu'il peut y avoir à combiner ces deux échelles de mesures dans un modèle de prédiction de l'indice de nutrition azotée (INN). En effet, des résultats concluants ont été obtenus dans le **chapitre 3** quant à l'utilisation du Dualex (Force A, Paris, France) couplée à des indices de végétation (IV) calculés à partir d'images prises par drone. Au stade 2 nœuds, le modèle PLS opérationnel créé en 2020 et testé sur le jeu de données de 2021 a permis d'obtenir un $R^2=0.59$ (0.45 sans NBI mesuré au Dualex), et le modèle de 2021 validé sur le jeu de données de 2020 un $R^2=0.72$ (0.37 sans NBI). Une fois ces modèles testés en parcelle agriculteur, cela pourrait ouvrir des perspectives intéressantes d'application pour du pilotage dynamique. Ainsi il paraît intéressant de compléter cette approche exploratoire par une étude des méthodes actuelles de pilotage de la fertilisation proposées aux agriculteurs afin d'évaluer leurs performances et envisager d'éventuelles améliorations à apporter.

En France, la méthode du bilan (Comifer, 2013) prédomine pour raisonner la fertilisation azotée. Cette méthode a pour objectif de permettre une nutrition non limitante de la culture tout en minimisant les pertes vers l'environnement. Pour cela, une dose totale d'N à apporter est calculée en amont de la campagne afin de combler l'écart entre les besoins de la culture et les fournitures en N (Comifer, 2013). Etant donné que la dose bilan est un calcul préalable, utilisant des références moyennes nationales ou régionales et fournissant une dose unique pour une parcelle, dans le but d'avoir une meilleure intégration de la variabilité spatiale et temporelle, des outils d'aide à la décision (OAD) ont été développés. Ceux-ci proposent, en partant de la dose bilan, d'adapter à la hausse ou la baisse la dose apportée en se basant sur une mesure du milieu, de la plante ou encore une estimation du développement du couvert.

Ces outils peuvent être des modèles (Azofert – INRAe – France, Index-N – Agroconseil – France), des capteurs aéroportés (Farmstar – Terres Innovia/Arvalis/Airbus – France, Wanaka – France), portatifs (N-tester – Yara – Norvège) ou embarqués sur tracteur (N-sensor – Yara – Norvège). Ils se basent sur différents principes de mesures (fourniture du sol, mesures de la plante, etc.) et sont capables de fournir une ou plusieurs informations liées à l'environnement et/ou au statut azoté de la plante ou du couvert (estimation de l'N absorbé à l'entrée du bilan, estimation d'une date d'apport, pilotage de la dose à apporter, spatialisation de la dose en fonction de l'hétérogénéité de la parcelle, etc.). Ainsi face à la diversité des outils disponibles sur le marché et à la multiplicité de conseils fournis, ce chapitre se propose de réaliser l'évaluation des performances agronomiques et environnementales de quatre de ces méthodes, à l'échelle d'une succession culturale et dans deux contextes pédologiques. Ce projet, mené de 2017 à 2020 a fait l'objet d'un financement de la part de l'Agence de l'eau Artois Picardie.

Ce chapitre présentera les résultats agronomiques et environnementaux obtenus à l'échelle de la succession orge-blé-colza-blé, sur les 2 parcelles expérimentales de Genech (59) et Izel- lès-Equerchin (62). L'analyse des résultats sera recentrée autour de la culture de blé, cible principale des OAD proposés à ce jour.

Les résultats obtenus dans le cadre de ce chapitre sont en préparation en vue d'une soumission pour publication dans la revue *European Journal of Agronomy*.

Agri-environmental performance of decision support tools (DST) used to monitor crop nitrogen fertilization strategies in the North of France

Bouchard M-A.^{1*}, Andriamandroso A.L.H.¹, Lebourg M., Vandoorne B.¹ and Andrianarisoa S.¹

¹ Université de Liège, Junia, UMRT 1158 BioEcoAgro - Conduction, optimization and design of cropping systems meeting multi-criteria objectives, B-5030 Gembloux, Belgique

*Corresponding author at: Junia, 2 rue Norbert Segard, 59800 Lille, France

E-mail address: marie-astrid.bouchard@junia.com

Abstract:

In France, decision support tools (DSTs) are used to adjust the crop nitrogen (N) fertilization. However, as they are based on different measurements and decision methods, farmers can receive contrasting advice for the same crop situation. This work aims to compare the agronomic and environmental performance of 4 DSTs using the classic balance sheet method (BSM). It was conducted between 2017 – 2020 for barley, wheat, and rapeseed on two experimental sites in the North of France according to a randomized block design with four replicates and six treatments: proximal sensing (PS), remote sensing with satellite (RS-S) or with UAV (RS-U), dynamic balance model (DBM), fertilized control with BSM and unfertilized (T0) treatments. The fertilizer N dose advised by DSTs was mostly higher than those calculated with the BSM (75% of situations), without any significant increases in either crop yield or in grain quality. For all crops in the two experimental sites, the relative number of situations in which DSTs advised higher values of fertilizer N than BSM was: RS-S (four out of four situations) > DBM (six out of seven) > PS (four out of seven) > RS-U (three out of six). The N dose was DST dependent and the difference with BSM reached up to 80 kg N.ha⁻¹ during one crop season for the same agropedological situation. The excess of fertilizer N was under utilised by crop and led to over-fertilization which was more pronounced in 2018 than 2020 due to particularly dry conditions. The over-fertilization explained the excess of soil mineral N content observed at harvest and over-fertilization beyond 50kg N.ha⁻¹ significantly increased the N excess in the soil at harvest ($R^2 = 0.42^{***}$). Our results raise the question of taking plant and soil N status evolution and climatic conditions into account in DSTs to determine the advised N dose.

Keywords: Nitrogen (N), decision support tools (DSTs), fertilization, balance sheet method

1. Introduction

In France over the last 50 years, technological and agro-ecological innovations have been made in crop systems to meet the challenge of productivity while considering the N losses in the environment (Meynard and Jeuffroy, 2019). Methods to estimate the optimal dose of mineral N to apply on crops have been proposed since 1978 and the first decision support tool (DST), AZOBIL, was developed by INRAe Laon, in 1990, to improve the management of plant nitrogen nutrition (Machet et al., 1990).

The Balance Sheet Method (BSM) (Comifer, 2013) is commonly used in France to minimize N losses and optimize crop grain yield and protein content. The recommended total N dose is estimated for all crops at the end of winter as the difference between crop N demand (N uptake, N losses) and soil mineral N (SMN) supply (stock and mineralization). For wheat in 90% of cases, this recommended N fertilizer dose is split into 3 or 4 applications (Degan et al., 2019), according to crop development stage and based on farmers' current practice, without exceeding the initial calculated value. Except for the SMN content measured at the end of winter, most BSM components used to calculate the recommended N dose are based on national or regional references or are estimated by the farmer himself. In addition, the assessment is performed at the beginning of crop growth and can therefore suffer from bias relative to the variability of local pedoclimatic conditions occurring throughout the crop cycle (Ravier et al., 2016).

DSTs were therefore developed to adjust the recommended N dose at the crop N status during the growth cycle. They were defined by the French Ministry of Agriculture, Agri-Food and Forestry (2017) as “all the techniques enabling to opt for the best possible decision, ie all the approaches to help reasoning N doses and their application dates”. Initially, these tools were developed for a better use of fertilizer inputs, avoiding low or over fertilization and applying the right amount of fertilizer in the right place and at the right time while matching crop demand (Diacono et al., 2013; Colaço and Bramley, 2018; Späti et al., 2021). DSTs were reported to increase fertilizer use efficiency without reducing the yield and quality at harvest (Diacono et al., 2013).

Today two kinds of tools are available for farmers: (i) DSTs based on *in situ* measurements and (ii) models-based DSTs.

- (i) The most widespread DSTs are based on *in situ* measurements of the soil or plant N status which is used to adjust the N fertilizer rate calculated according to the BSM. These measurements are made by direct soil or plant sampling or by indirect monitoring with sensors. Different sensing approaches are available, ranging from handheld devices (eg N-tester, Yara, Norway), tractor-mounted sensors (eg N-sensor, Yara, Norway), drones (eg Wanaka, France) to satellite imagery (eg Farmstar, Terres Innovia/Arvalis/Airbus, France) (Späti et al., 2021). According to the *in situ* measurements, advice is provided for farmers to modulate the last fertilizer N application rate upwards or downwards. Depending on the sensor, the N application rate can be modulated at the whole field level, or according to the spatial variability of N requirements in the field, allowing site-specific management.
- (ii) Model-based DSTs are also developed to optimise N fertilization by simulating crop growth and updating some BSM components according to the local pedoclimatic conditions (Meynard et al., 2002). Simulation is performed daily by considering mean climate data. Thus, the evolution of different N dynamics can be estimated in soil, crops and the environment (N applications, mineralization, leaching, volatilization, microbial organisation of the fertilizer). These tools enable the farmer to determine the optimal dates and split of fertilizer applications (Meynard et al., 2002).

Literature reviews showed that the use of DSTs results in a 5 to 45% reduction in N fertilizer application without significant decrease in crop yield and quality (Colaço and Bramley, 2018); an increase in N use

efficiency (NUE) by as much as 368% in the best case in comparison to standard fertilization practices (Li et al., 2009; Diacono et al., 2013); a reduction in residual N in the soil by 30-50% (Diacono et al., 2013); and, finally, a profitability increase by 5 to 60 \$.ha⁻¹ by comparing the spatial variability of N requirements to undifferentiated applications (Diacono et al., 2013). As in the field, the adoption of DSTs by farmers is highly dependent on the method's profitability. Much of the research is therefore focused on studying the economic benefits of fertilizer modulation (Diacono et al., 2013). Moreover, it is more complicated for farmers to assess the environmental impacts of these practices, which are not always noticeable at field level. Finally, even if some DSTs are based on *in situ* measurements, the associated decision rules are based on non-limiting crop nutrition and on critical threshold values which can lead to over-fertilization (Lemaire, 2019).

In France, the French Ministry of Agriculture, Agri-Food and Forestry (2017) inventoried DSTs already available and used by farmers. Given the diversity in methods and technologies, the advice provided to farmers are DSTs dependant. Studies comparing the advice from different DSTs for the same agropedological situation for crop growth and quality and for N use efficiency at plot level are missing. This work aims to fill this gap by comparing the advice provided by different DSTs for N fertilization and by evaluating their agronomic and environmental performance at the crop's rotation scale. The study was conducted at two experimental sites with contrasted pedoclimatic context in the North of France, from 2017 to 2020.

2. Materials and Methods

2.1. Study sites

The study was conducted over four crop years from 2017 to 2020 at two experimental sites in Genech (50°31'12.7"N 3°12'35.5"E) and Izel-les-Equerchin (50°20'54.3"N 2°55'57.5"E) in the North of France (Figure 1), 20 km and 38 km from Lille city respectively. The soil type was a deep brunisol with silt loam texture in Genech, and a shallow rendosol (WRB, FAO, 2014) with a silty clay loam texture and a high content of limestone in Izel-les-Equerchin. The soil profile in Izel-les-Equerchin consisted in 30 cm of organo-mineral layer and 20 cm of weathered limestone. The parent material was composed of cracked soft limestone from 50 cm depth. Soil parameters measured at different depths for both experimental sites are summarized in Table 1. The average annual rainfall and temperature calculated from 1981-2010 was 743mm per year and 10.8°C respectively (data from Meteo France: Lille-Lesquin weather station). In comparison with average data, the study years (2017-2020) were deficient in rainfall: from -8.6% in 2017 to -16.6% in 2018. These differences reached -50% in 2017 and -36% in 2020 during the crop fertilization period (Figure 2).




Figure 1 : Location of the experimental sites (a) and schematic presentation of the randomized block design in Genech (b) and Izel-les-Equerchin (c). BSM: control plot fertilized with the recommended N dose calculated with Balance Sheet Method. TO : unfertilized control plot. PS : proximal sensing. DBM : dynamic balance method. RS-S : remote sensing with satellite. RS-U : remote sensing with unmanned aerial vehicle (UAV).

Table 1 : Physico-chemical soil parameters measured in Genech (n=24 soil samples) and Izel-les-Equerchin (n=6 soil samples per layer) experimental sites. Soil analyses were performed by the LDAR laboratory in France except for bulk density which was performed by the Earth and Life Institute / Environmental Sciences (ELI-e) from Catholic University of Louvain. Values are means.

Physicochemical parameters		Method	Genech	Izel-les-Equerchin	
Thickness	cm		0-30	0-30	30-90
Coarse fraction	%	Sieving	0	23	34
Clay	%	modified NF X 31-107	15	32	53
Loam	%	modified NF X 31-107	50	52	28
Sand	%	modified NF X 31-107	34	16	20
CaCO ₃	%	NF ISO 10693	< 1	60	55
Water pH		NF ISO 10390	7.5	8.5	8.6
Bulk density		Cylinder	1.5	1.4	1.4
Organic C	g.kg ⁻¹	NF ISO 14 235	9.5	12	10.1
Organic matter	g.kg ⁻¹	(2 x C.org)	19	24	20
N total Kjeldahl	g.kg ⁻¹	Modified NF ISO 11261	0.9	1.2	1.1
C/N ratio			10.6	9.6	9.3

The experiment was set up in Genech in 2016 with a barley (*Hordeum vulgare* L.) crop and in Izel-les-Equerchin in 2017 with winter wheat (*Triticum aestivum* L.). The studied crop succession was winter barley / winter wheat / rapeseed (*Brassica napus* L.) / winter wheat in Genech and winter wheat / rapeseed / winter wheat in Izel-les-Equerchin. The previous crop before the experiment was maize in Genech and potatoes in Izel-les-Equerchin. Table 2 summarizes the crop management practiced since 2016. The crop variety was Hunic for rapeseed, Zoo for barley, and Amboise (2018) and Rubisko (2020) for winter wheat. Details about their characteristics are available on the GEVES website (French variety and seed study and control group, <https://www.geves.fr/catalogue/>). The soil was ploughed every year at the two experimental sites at a depth less than 25 cm the day before sowing. The cereal's straws were exported from the plot whereas rapeseed straws and siliques were cut, returned, and incorporated into the soil with ploughing. No cover crops were sown between 2016 and 2020. Pests were controlled along crop cycle by applying the recommended amount of phytosanitary products.

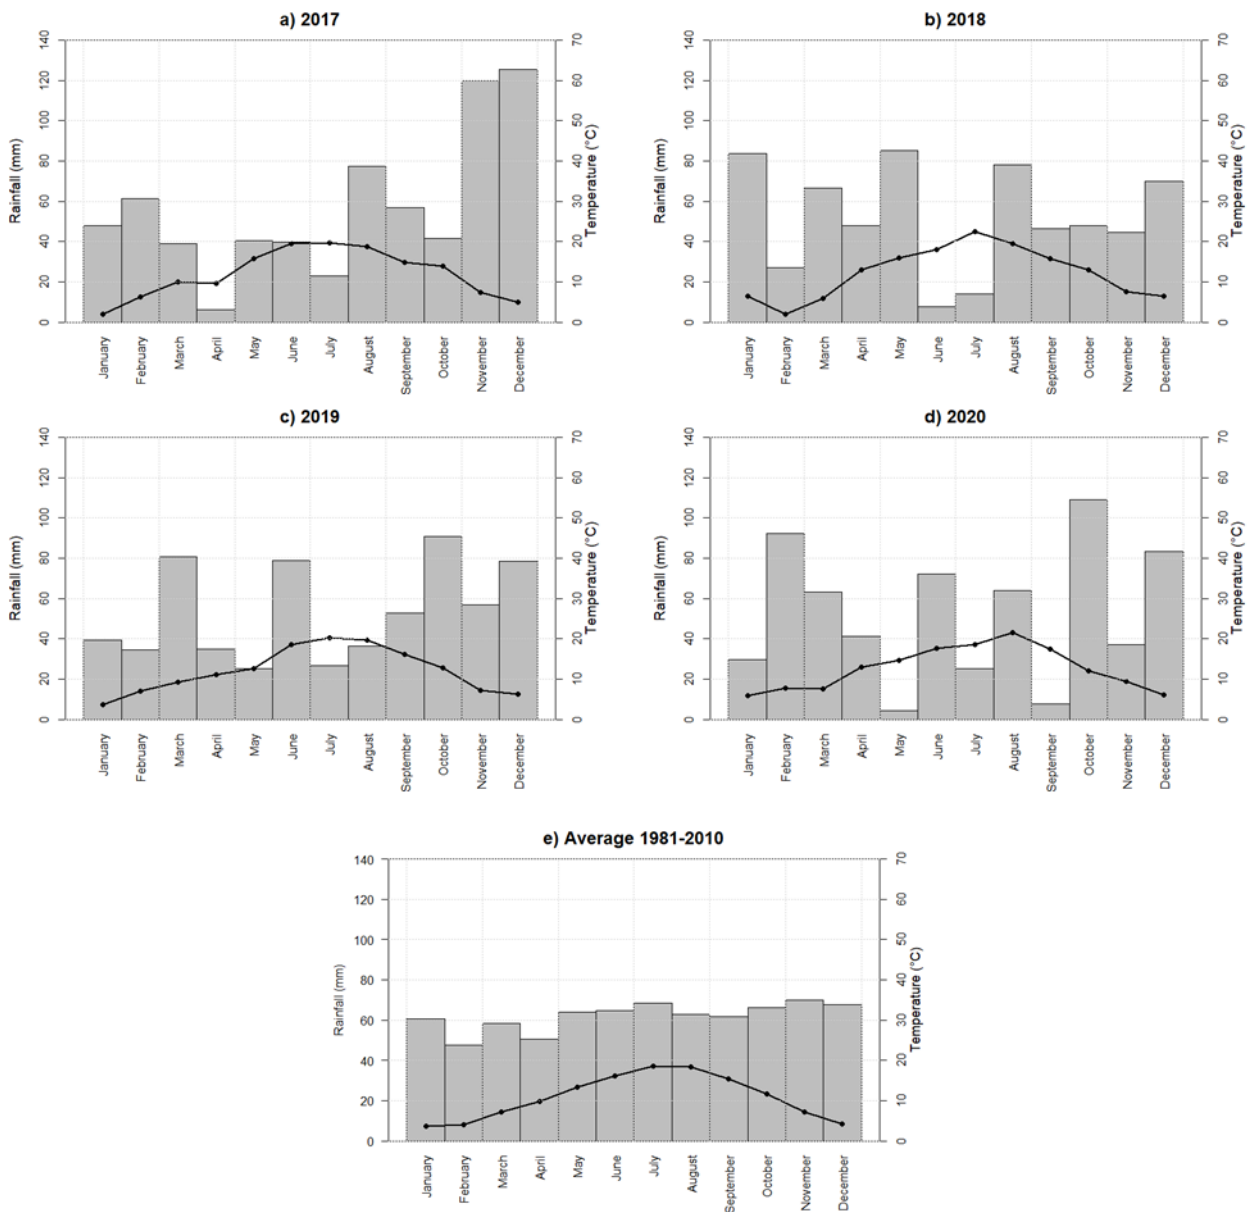


Figure 2 : Ombrothermic diagrams of Gaussen for Lille-Lesquin weather station in 2017 (a), 2018 (b), 2019 (c), 2020 (d) and between 1981 to 2010 (e) (data from MétéoFrance: Lille-Lesquin weather station)

Table 2 : Summary of crop management practices at the Genech and Izel-les-Equerchin-les-Equerchin experimental sites from 2016 to 2020 (*Details about crop varieties are available on the GEVES website: <https://www.geves.fr/catalogue/>)

Experimental site	Crop	Year	Cultivar*	Sowing		Harvest		N fertiliser application				Objective Yield (Mg.ha ⁻¹)
				Date	Density (seeds.m ⁻²)	Date	Date 1	Date 2	Date 3	Data 4		
Genech	Barley	2016/2017	Zoo	12/10/16	170	22/06/17	23/03/17	13/04/17	11/05/17	-	-	9.0
	Wheat	2017/2018	Rubisko	07/11/17	300	26/07/18	20/03/18	13/04/18	02/05/18	17/05/18	10.0	
	Rapeseed	2018/2019	Hunic	24/08/18	33	01/08/19	11/03/19	10/04/19	-	-	3.5	
	Wheat	2019/2020	Amboise	29/10/19	350	22/07/20	03/04/20	21/04/20	14/05/20	-	9.0	
Izel-les-Equerchin	Wheat	2017/2018	Rubisko	09/01/18	350	26/07/18	10/04/18	16/05/18	28/05/18	08/06/18	10.0	
	Rapeseed	2018/2019	Hunic	24/08/18	33	31/07/19	11/03/19	10/04/19	-	-	3.5	
	Wheat	2019/2020	Amboise	21/10/19	221	29/07/20	02/04/20	20/04/20	13/05/20	-	9.5	

For each site, the experiment was conducted in a randomized block design including six treatments and four replicates (Figure 1). Treatments were made according to the type of DST used to pilot the crop N fertilization along the crop cycle. They were applied to 24 microplots of 240m² (12m width, 20m length). Four DSTs which are available in the field and are representative of farmers' practices were tested and compared with two control treatments: T0, which was unfertilized, and BSM fertilized with the recommended N dose calculated according to the balance sheet method without any use of DSTs. The formula for BSM calculation is given in Eq. 1 and 2 (Comifer, 2013; Meynard et al., 1997; Beaudoin et al., 2005):

$$X = (U_2 + N_2 + L + G) - (M + N_1 + U_1 + A) \quad (\text{Eq. 1})$$

Where X = recommended N dose; U₂ and U₁ = N uptake by the crop at harvest and at the end of winter respectively; N₂ and N₁ = SMN content at harvest and at the end of winter respectively; A = meteoritic N input; G = gaseous N losses (denitrification and volatilisation); L = N leaching losses during the cropping out of rooting zone; M = net N mineralization by the soil during cropping. All values are in kg N.ha⁻¹.

$$U_2 = b * Y \quad (\text{Eq. 2})$$

Where Y = objective yield (Mg.ha⁻¹); b = amount of nitrogen absorbed per unit of yield (kg N.Mg⁻¹).

The different components of BSM were either measured (N₁, U₁), estimated from models or national and regional references (b, N₂, L, G, M, A), or provided directly by farmers (Y). The U₁ component was measured every year in mid-February. Y was the average yield of the given crop for the last five harvests. Values of Y are presented in table 2.

Thereafter, the recommended N dose was split into two to four applications according to crop type (Comifer 2013). Fertilizer application dates were defined according to crop growth stages. As the key growth stages for cereals' fertilizer N application are from the end of winter at tillering stage, before stem elongation at stage ear 1cm, and between two nodes and booting stages, respectively GS26, GS30 and GS32-Z45 (Zadoks et al., 1974). Three and four fertilizer N applications were carried out for barley and winter wheat respectively. For rapeseed, two applications were made at the beginning of elongation stages (BBCH 30) and at the inflorescence emergence (BBCH50).

Three DSTs based on *in situ* measurement and one model-based DST were tested during this study:

- (1) Proximal sensing (PS): a clip-on hand-held chlorophyll meter (N-tester[®], Yara International ASA, Norway), based on leaf transmittance measurement for cereals and a smartphone application (Image-IT[®], Yara, Norway) for rapeseed. For cereals, the transmittance was measured at mid-length of the uppermost fully expanded leaf from 30 randomly selected plants per subplot. For wheat, measurements were taken between growth stages (GS) GS32 and GS43, which corresponds to the second node and the boots just visible swollen stage respectively. For barley, it was carried out between GS31 and GS32. The N-tester values were converted into a dose of N to be applied in the plot according to a grid from Yara International. Thus, according to the plant N status at the measurement stage, the amount of the last N fertilizer application was modulated upwards or downwards according to the DST recommendations.

For rapeseed, the plant biomass and the amount of N already absorbed by the crop (U₁) were estimated from images taken by a smartphone at the end of winter. The estimation by the Image-IT program is based on the pictures used to calculate the canopy cover index, the rate of green pixel and the evaluation of the senescent leaves, corrected with the height of the canopy. Four images were taken horizontally at a height of 1m from the soil surface in an area randomly chosen within the plot. The value of biomass and U₁ were directly given by the

smartphone image-IT application and were used to correct the value of U_1 in the BSM method. Usually, for the BSM calculation for rapeseed, the biomass is evaluated at the end of winter by a direct weighting of fresh plants uprooted from a 1m² area. The U_1 value is obtained using a referential grid provided by Terres Inovia institute (the French institute specializing in oilseeds plant) according to the plant biomass value.

- (2) Remote sensing (RS): Unmanned Aerial Vehicle (UAV) or UAV-based advice (RS-U), based on reflectance measurements from UAV images, and satellite-based advice (RS-S), based on reflectance measurements from satellites images, were tested. The tested RS-S was Farmstar developed by Arvalis institute (Blondot et al., 2005). First, the U_1 term of BSM was adjusted through remote sensing techniques in order to have a better assessment of the amount of N absorbed at the end of winter, rather than using a mean value based on national references. A corrected BSM value was then proposed with a number of N applications remaining the same. Thereafter, the plant's N status was diagnosed during stem elongation, based on the leaf chlorophyll content to decide whether the last N application planned using the BSM should be adjusted upwards or downward to meet crop N requirements. The same reasoning was applied for RS-U, however, the leaf chlorophyll content was obtained by a drone flyover between GS32 and GS37 for cereals. For rapeseed, measurements were made to estimate U_1 both at the beginning and at the end of winter for RS-S and RS-U. The DST gave a map of the applied dose at the level of the whole plot. The advice was applied at subplots level, so all subplots were drawn on the RS-S and RS-U modulation maps to extract an average value per microplot.
- (3) model-based DST: this DST uses a dynamic balance method (DBM) based on the Index N model (Geypens et al., 1994; Vandendriessche et al., 1996). It provides advice on how to modulate each N application, and to decide the date and fertilizer N dose. The Index N model estimates the N available for the crop according to 18 parameters distributed into three groups: N available for crop (SMN content, N applications, etc.); N provided during the crop cycle (mineralization); and N losses. At each application date, the model re-assessed the available N according to the evolution of the different parameters during crop growth. This allows the N rate advised to be adjusted. Unlike the 3 first DST, the BSM recommended dose was not used by the model.

Throughout the experiment, no external organic amendments were added. The mineral N fertilizer were supplied in solid ammonium nitrate form (27% of N) with a ratio $\text{NO}_3^- : \text{NH}_4^+$ of 50:50. The correct amount of fertilizer was applied per microplot with a Nodet DP-12 fertilizer spreader. Concerning fertilization dates (Table 2), for barley, rapeseed and wheat in 2020, applications dates were the same for each DSTs and BSM. In Genech in 2018, fertilization dates were the same for each DST, except for DBM where the 3rd and 4th inputs were shifted by 15 days compared to the other DSTs. In 2018 for Izel, only DBM and RS-U had a 4th application.

2.2. Field measurements

2.2.1. Agronomic parameters

The agronomic performance of DSTs was assessed by measuring yield and grain quality (oil and protein content for rapeseed and cereals respectively) at harvest. Yield was measured from a 31 m² area (1.55 m width, 20 m length) chosen at the middle of each microplot to avoid edge effects. Harvest was carried out using a combine harvester equipped with on-board weighing and moisture measurements. An aliquot of 1 kg grain was then kept per microplot to measure the protein or oil content using an infrared spectroscopy (infralyzer). Depending on grain moisture, yield values were corrected to reach 15% moisture content.

For wheat, the total aerial biomass and the N concentration of straw and grains were measured at harvest. In 2018, all plants from a 2.25m² area randomly chosen within each microplot were cut with

knife at soil surface. In 2020, 10 plants were randomly taken from each microplot and weighed. The fresh areal biomass was calculated using the number of plants counted on a 1 m² area. Spike and straw were separated and an aliquot was oven-dried at 65°C to determine the dry biomass. After fine grinding of both parts, the N content was analyzed using the Dumas method (NF EN ISO 16634-1). The amount of N absorbed by the plant at harvest was calculated according to Eq. 3:

$$N_{uptake} \text{ (kg.ha}^{-1}\text{)} = \%N \text{ grain} \times \text{DM grain} + \%N \text{ straw} \times \text{DM straw} \quad (\text{Eq. 3})$$

Where %N grain and %N straw were the N content of grain and straw respectively and DM grain and DM straw were the dry biomass of grain and straw respectively in kg.ha⁻¹.

2.2.2. Environmental parameters

Throughout the study, the soil N mineral content was monitored for each microplot, twice per crop year: in mid-February before growth resumption, and at harvest. At least three soil cores per microplot were taken with an auger down to 90 cm depth and gathered per layer of 30 cm thick (ie 0-30 cm, 30-60 cm, 60-90 cm) to make a composite sample. Soil samples were sieved at 4 mm and stored at in a cold room (-10°C) before analysis. Soil moisture was measured by drying an aliquot of fresh soil at 105°C for 48h. Soil bulk density was measured at the beginning of the experiment using a cylinder method for each soil layer. For all sampling dates, inorganic N was extracted by checking 6 g of fresh and thawed soil samples with 30 ml of K₂SO₄ (0.5M). The SMN concentration (NH₄⁺ and NO₃⁻) of extracts was determined using continuous flow colorimetry analyser (San++, Saklar Analytical B.V., Breda, The Netherlands). SMN was calculated as mg.kg⁻¹ of dry soil or kg N.ha⁻¹, using the soil bulk density measured above. A duplicate of frozen soil samples collected at the end of winter was also sent to an external laboratory (Aurea, Paris, France) to obtain the advice for the recommended N dose as a farmer would have done. Values of measured soil bulk density were given to the Aurea laboratory for the conversion between mg N.kg⁻¹ into kg N.ha⁻¹.

A parameter called Apparent Nitrogen Recovery (ANR), defined as the difference in N uptake between a fertilized crop (Tx) and an unfertilized crop (T0) relative to the amount of N applied (X), was calculated as follows (Limaux, 1999):

$$\text{ANR} = \frac{T_x - T_0}{X} \quad (\text{Eq. 4})$$

Lastly, by comparing the predicted recommended N dose calculated with BSM and the actual N fertilizer rate, and the measurements of plant N content and yield at harvest, a parameter called over-fertilization (OF) was calculated using the formula proposed by Beaudoin et al. (2005):

$$\text{OF} = (\text{Tx} - \text{BSM}) + b(\text{Y} - \text{Y}') \quad (\text{Eq. 5})$$

Where, OF = over-fertilization; Tx = actual N fertilizer rate (according to DST advice); BSM = predictive recommended N fertilizer (calculated with the BSM); b = amount of N absorbed per unit of yield; Y = objective yield; and Y' = actual yield.

At harvest, the difference (ΔN) between the predictive (N₂, see equation 1) and the measured residual SMN (N₂') up to 90cm was also calculated:

$$\Delta N = N_2' - N_2 \quad (\text{Eq. 6})$$

The predictive value of N₂ was estimated according to the soil depth and texture based on a grid proposed by INRAE (2012) (in Comifer, 2013) and used by farming advisor such as Aurea laboratory cited above.

2.2.3. Statistical analysis

Relative deviations from BSM treatment for N fertilizer rate, crop yield, grain quality and soil mineral N were calculated according to the following Eq 7:

$$\text{Relative deviation (N fertiliser rate, crop yield, grain quality, SMN)} = \frac{100 \times (\text{DSTsresult} - \text{BSMresult})}{\text{BSMresults}} \quad (\text{Eq. 7})$$

The average of the relative deviation from BSM over the whole crop succession for both experimental sites was then compared between DSTs with a student test ($p < 0.05$), regardless of sites (Figure 3).

For the Genech and Izel-les-Equerchin experimental sites, mixed analysis of variance (ANOVA) with block as the random factor was made to evaluate the effect of applied N fertilizer advised by DSTs on crop yield, grain protein or oil content, ANR and crop N uptake for a given crop. A post hoc Dunnett's test procedure was then performed to compare the means of each variable measured for each DST and in T0 with those from BSM considered as a reference treatment ($p < 0.05$) (Table 3). Comparison of means of N fertilizer rate between DST and control treatments at the level of crop year was not carried out because, except PS, all DSTs advised an unique value of N fertiliser rate for the 4 replicates.

For BSM treatments, a mixed ANOVA with block as the random factor was carried out to evaluate (i) the effect of the measurement period on the SMN content at 90cm depth between 2017 and 2020 in Genech and Izel-les-Equerchin; and (ii) the effect of soil depth on SMN content for a given period of measurement regardless of crop type or experimental sites (Figure 4). Thereafter, Tukey post-hoc tests were made to compare the mean of SMN values measured at 90 cm depth between date of measurement and the mean of SMN values between soil layer for a given date of measurement. A mixed ANOVA followed by a posthoc Dunnett's comparison test were performed to compare the average relative deviation from BSM of SMN content between each DST and T0 (Figure 5).

Lastly, a linear regression analysis was carried out to evaluate the relationship between the over-fertilization calculated in Eq 5 and the ΔN in Eq 6. The coefficient of determination of the regression was calculated and the significance of the linear model determined. In figure 7, a significant coefficient of determination at $p < 0.001$ is indicated with symbol « *** ».

All statistical analyses were performed with RStudio software (RStudio Team 2019, version 3.6.2). Mixed ANOVAs and post-hoc tests were made with nlme (Pinheiro et al., 2021) and multcomp (Hothorn et al., 2008) R packages.

3. Results

3.1. Overall synthesis of N fertilization, crop yield and grain quality

When considering all data, the mean applied fertilizer N quantity over all years and crops was 180 kg N.ha⁻¹ and was not significantly different between Genech (183 kg N.ha⁻¹) and Izel-les-Equerchin (178 kg.ha⁻¹) even though data from 2017 is excluded (196 kg N.ha⁻¹ in Genech). It was 116 kg N.ha⁻¹ and 192 kg N.ha⁻¹ for barley and rapeseed respectively. For wheat, the amount of N fertilizer varied between years but not between sites. For instance, the mean N input of all modalities was significantly higher in 2018 (215 kg N.ha⁻¹) than in 2020 (180 kg N.ha⁻¹) in Genech, whereas no significant difference was observed either in Izel-les-Equerchin between 2018 (179 kg N.ha⁻¹) and 2020 (160 kg N.ha⁻¹) or

between Genech and Izel-les-Equerchin (Table 3). On average, the number of fertilizer N split varied by year and site and ranged from two for rapeseed to four for wheat.

In response to N fertilization, the crop yield and quality varied between years and experimental site. In Genech, for all fertilized treatments, the mean crop yield was 7.7, 9.1, 3.7 and 10 Mg.ha⁻¹ for barley 2017, wheat 2018, rapeseed 2019 and wheat 2020 respectively. The mean protein content of cereals was 9.8% for barley, 11.8% and 10.8% for wheat in 2018 and 2020. The mean oil content of rapeseed grain was 44.7%. In Izel-les-Equerchin, the mean crop yield was 8.2, 3.2 and 10 Mg.ha⁻¹ for wheat 2018, rapeseed 2019 and wheat 2020 respectively. The mean protein content of wheat was 12.3% and 10% in 2018 and 2020 respectively, while the mean oil content of rapeseed was 45%.

3.2. Agronomic performances of DSTs

3.2.1. Performances over the crop succession

For all experimental sites and crops, results showed that, on average, DSTs advised more N fertilizer amount than BSM (Figure 3). The average relative deviation N fertilizer rate from BSM ranged from +5% for RS-U to +33% for DBM. Statistical analysis performed at crop succession level showed that only the N fertilizer rates advised by DBM were significantly higher than the recommended N dose by BSM. This high N fertilizer rate value for DBM allowed on average a significantly higher crop yield (+6%) to be obtained compared to BSM without any significant improvement in grain quality. For the other studied DSTs, because the advised fertilizer rates were not significantly different from BSM, the crop yield and grain quality were also similar. By comparison with TO treatment, the significant high amount of N fertilizer applied in BSM over the 4-year period substantially increased the crop yield but not the grain quality at harvest.




Figure 3 : Average relative deviation from BSM for N fertilizer rate, crop yield and protein/oil content. Values are means calculated for all crop years and experimental sites. Bars are the standard errors. Stars are results of t-test comparison between means calculated for a given DST and the recommended BSM dose. Significance of the codes: p-value < 0.001 (***), p-value < 0.05 (*) and p-value > 0.05 (ns)

3.2.2. Diagnoses of fertilizer N strategies advised by DSTs at crop year level

For each year and each experimental site, every DST advised a unique N dose for the 4 blocks, except PS and RS-U in 2017 and 2018, where variability of advised N dose was observed between blocks. The standard deviation of N fertilizer dose for these two DSTs ranged from ± 0 to ± 33 kg N.ha⁻¹. Consequently, no variance analysis was carried out to compare the dose of fertilizer N at the level of crop year. Considering all crop years and the two experimental sites, we counted the relative number of situations in which the DSTs advised higher values of fertilizer N than BSM. A classification can be made as follows: RS-S (four out of four situations) > DBM (six out of seven situations) > PS (four out of seven situations) > RS-U (three out of six situations). Conversely, for situations in which DSTs advised lower values of fertilizer N than BSM, the classification was: RS-U (three out of six) > PS (two out of seven) > DBM (one out of seven) > RS-S (zero out of four).

In 75% of situations, DSTs advised higher N fertilizer rates than BSM. The RS-S always advised a higher amount of fertilizer N dose than BSM. In the four situations, the difference of dose between BSM and RS-S ranged from + 4 kg N.ha⁻¹ in 2018 for wheat, to + 40 kg N.ha⁻¹ in 2019 for rapeseed at the Izel-les-Equerchin and Genech experimental sites respectively. The DBM was the second DST that maximized the number of times where the BSM dose was exceeded. The difference in fertilizer N dose between DBM and BSM reached 78 kg N.ha⁻¹ in 2017 for barley and 80 kg N.ha⁻¹ in 2018 for wheat at Genech and Izel-les-Equerchin experimental sites respectively. Out of seven situations, only one advice was lower than BSM: -10 kg N.ha⁻¹ for rapeseed in 2019 at the Genech experimental site. For the remaining 25% of situations where a dose reduction was advised, the amount of fertilizer N saved using the BSM range from -2% for PS in Izel-les-Equerchin in 2018 to -16% for RS-U in Genech in 2020 (Table 3).

Regarding the number of fertilizer N splits, all DST advised a number of splits higher or equal to those advised by BSM, except for PS in two situations out of seven, especially at the Genech experimental site and for RS-U in Izel-les-Equerchin in 2020. For rapeseed, all DST agreed with the BSM to split the N dose into two applications. For wheat, while the number of splits advised by DSTs was similar to the BSM in Genech, the DSTs did not always agree with BSM at Izel-les-Equerchin experimental site. For instance, DBM always advised one more supply of N fertilizer at this experimental site – the same as RS-U in 2018 and PS in 2020. This additional fertilizer N explained the higher total amount of N dose for these three DSTs for the given years at this experimental site.

Concerning fertilizer application dates between DSTs, for the three DSTs based on in situ measurements, the fertilizer application date was the same as those planned by BSM (Table 2). However, for the number of splits higher than BSM, a new date later than the last one planned in BSM was added with a new dose. This was the case for RS-U in 2018 in Izel-les-Equerchin. For situations where the number of splits was lower than BSM, it means that the last planned fertilizer supply has been deleted. For DBM, the application dates were dependent on the growing stages. Therefore, even if the number of splits was the same as BSM, in some cases applications dates were offset. For DBM, this was the case for wheat in Genech in 2018.

3.2.3. Diagnosis of crop response to N fertilizer

In comparison with BSM, all DSTs did not change either the crop yield or the grain quality despite, the increase or the reduction of the advised N dose. Exception should be noted for one situation in 2020 where the wheat protein content was + 13.5% higher for PS compared to BSM (Table 3). However, this exception was not due to the amount of N fertilizer because for the same crop year, the N dose advised by DBM was higher than those proposed by PS. The application dates were also the same as BSM.

Finally, when comparing the T0 treatment with BSM, crop yields obtained without any N mineral fertilization were significantly lower. It represents in average a reduction of 58% in comparison with

the yield harvested in BSM, when considering all crops in both experimental sites every year. It was on average 65%, 47%, 64% of crop yield in BSM for barley, wheat, rapeseed in Genech, and 57%, 71% for wheat and rapeseed in Izel-les-Equerchin respectively. For grain quality, results in T0 varied according to crop, year and site. For instance, in Genech, zero fertilization decreased the protein content of barley and wheat by -3% and -3.5% of protein respectively whereas no significant effect was observed for rapeseed oil content neither in Genech nor in Izel-les-Equerchin. In Izel-les-Equerchin, zero fertilization decreased the protein content of wheat in 2018 only, when the values measured in fertilized wheat were high. In 2020, no significant decrease in protein content was observed between fertilized and unfertilized treatments but values were lower than in 2018.

Table 3 : Summary of annual agronomic variables monitoring according to DSTs used in the Genech and Izel-les-Equerchin experimental sites. Values are means (\pm SD). Means with symbols “***” or “**” or “*” are significantly different to the means calculated in the control BSM plot for the given crop year and site at p-value < 0.001 or < 0.01 or < 0.05 respectively (Dunnett’s test). Means without any symbols are not significantly different to the means calculated in BSM treatment for a given crop year and site.

Experimental site		Genech				Izel-les-Equerchin			
Crop	Tested DSTs	N dose (kg N.ha ⁻¹)	Number of splits	Crop yield (Mg.ha ⁻¹)	Crop quality (% protein/oil)	N dose (kg N.ha ⁻¹)	Number of splits	Yield (Mg.ha ⁻¹)	Crop quality (% protein/oil)
Barley 2017	BSM	94	3	7.5	10				
	PS	83 (\pm 20)	2-3	6.9	8.2				
	RS-S	-	-	-	-				
	RS-U	-	-	-	-				
	DBM	172	3	8.6	11.2				
	T0	0	-	4.9***	7.0***				
Wheat 2018	BSM	200	4	9.1	11.9	156	3	8.1	12.5
	PS	200 (\pm 20)	3-4	9.3	11.4	153 (\pm 33)	3	8.0	11.9
	RS-S	210	4	9.0	11.7	160	3	8.2	12.2
	RS-U	228	4	9.3	11.9	190 (\pm 30)	4	8.1	12.2
	DBM	236	4	8.9	11.8	236	4	8.5	12.5
	T0	0	-	4.0***	8.4***	0	-	5.2***	11.1***
Rapeseed 2019	BSM	170	2	3.6	44.8	180	2	3.1	45.3
	PS	210	2	3.5	44.3	200	2	3.3	45.7
	RS-S	210	2	3.7	44.6	200	2	3.3	45.3
	RS-U	210	2	3.8	45.1	170	2	3.3	45.4
	DBM	160	2	3.9	44.9	210	2	3.2	45.5
	T0	0	-	2.3***	44.6	0	-	2.2**	45.4
Wheat 2020	BSM	179	3	9.8	10.4	136	2	10.0	9.4
	PS	193	3	9.7	11.8***	170	3	10.1	9.9
	RS-S	-	-	-	-	-	-	-	-
	RS-U	150	3	10.4	10.8	125	2	9.4	9.5
	DBM	201	3	10.0	10.3	207	3	10.6	10.0
	T0	0	-	4.8***	6.8***	0	-	4.9***	8.9

3.3. Environmental performances of DSTs

3.3.1. Evolution of soil mineral nitrogen (SMN) content in balance sheet method (BSM) treatment

At the Genech experimental site, for BSM treatment, the mean value of SMN content on a 90 cm soil profile ranged from 19 kg N.ha⁻¹ in February 2018 to 69 kg N.ha⁻¹ in February 2020. During the first three years (2017, 2018, 2019), SMN values were not significantly different between all measurement dates: the mean value was 20 kg.ha⁻¹ at the end of winter and 30 kg.ha⁻¹ at harvest in July (Figure 4a). However, SMN significantly increased from harvest 2019 (28 kg N.ha⁻¹) to the end of winter 2020 (69 kg N.ha⁻¹) and remained high until harvest 2020. For this last year, the SMN measured at the end of winter 2020 in the 30 – 60cm depth significantly increased compared to values measured in July 2019 at rapeseed harvest. Between February 2020 and July 2020 for the wheat crop, the SMN measured in 30 – 60cm depth significantly decreased, but the total value measured over a depth of 90cm remained the same for both dates. When focusing on harvest, results showed that all SMN measured over that period exceeded the predictive value proposed by Comifer (2013) for this kind of soil and at this depth. The excess was particularly high in July 2020 (+ 57kg N.ha⁻¹).

At the Izel-les-Equerchin experimental site, the SMN measured over a depth of 90cm ranged from 31 kg.N.ha⁻¹ (February 2019) to 97 kg N.ha⁻¹ (July 2019) (Figure 4.b). For the same calendar year, SMN measured at the end of winter was not significantly different to that measured at harvest. In February 2018 at the beginning of the experiment after a potato crop, the value of SMN was the highest among all measurement dates in the deep layer composed mainly of soft cracked chalk. At the wheat harvest in summer, the amount of SMN in the chalk layer remained stable but, as a high amount of SMN was also observed in the upper soil layer, the SMN measured over the 90cm depth reached the highest value for all measurement dates. Between the wheat harvest in 2018 and February 2019, the SMN considerably decreased (-66 kg N.ha⁻¹) due to a combined effect of the rapeseed crop sowed 5 days after the wheat harvest, and the high amount of rainfall during this period (368 mm between July-18 and February-19 incl.). At the rapeseed harvest in 2019, the SMN significantly increased for the two upper layers, but the overall value measured on the 90cm depth remained unchanged. In 2020, unlike previous years, the SMN decreased, significantly for the two deep layers between February and July. When focusing only on harvest, results showed that all SMN values measured over the three years of monitoring exceed the predictive value proposed by Comifer (2013). The excess was particularly high in July 2018 due to high amount of SMN in soil surface.




Figure 4 : Evolution of soil mineral N content at 90 cm depth between 2017 to 2020 for microplots fertilized with BSM treatment at the Genech (a) and Izel-les-Equerchin (b) experimental sites. Histograms are means (n=4) and vertical bars are standard errors. Letters are results of Tukey's test for means comparison ($p < 0.05$) between all dates of measurements: in lower case for comparison layer per layer and in uppercase the comparison for 90cm depth. Means with the same letters are not significantly different. The horizontal line represents the predictive residual soil mineral N at harvest according to COMIFER (2013).

3.3.2. Evolution of SMN for DSTs treatments

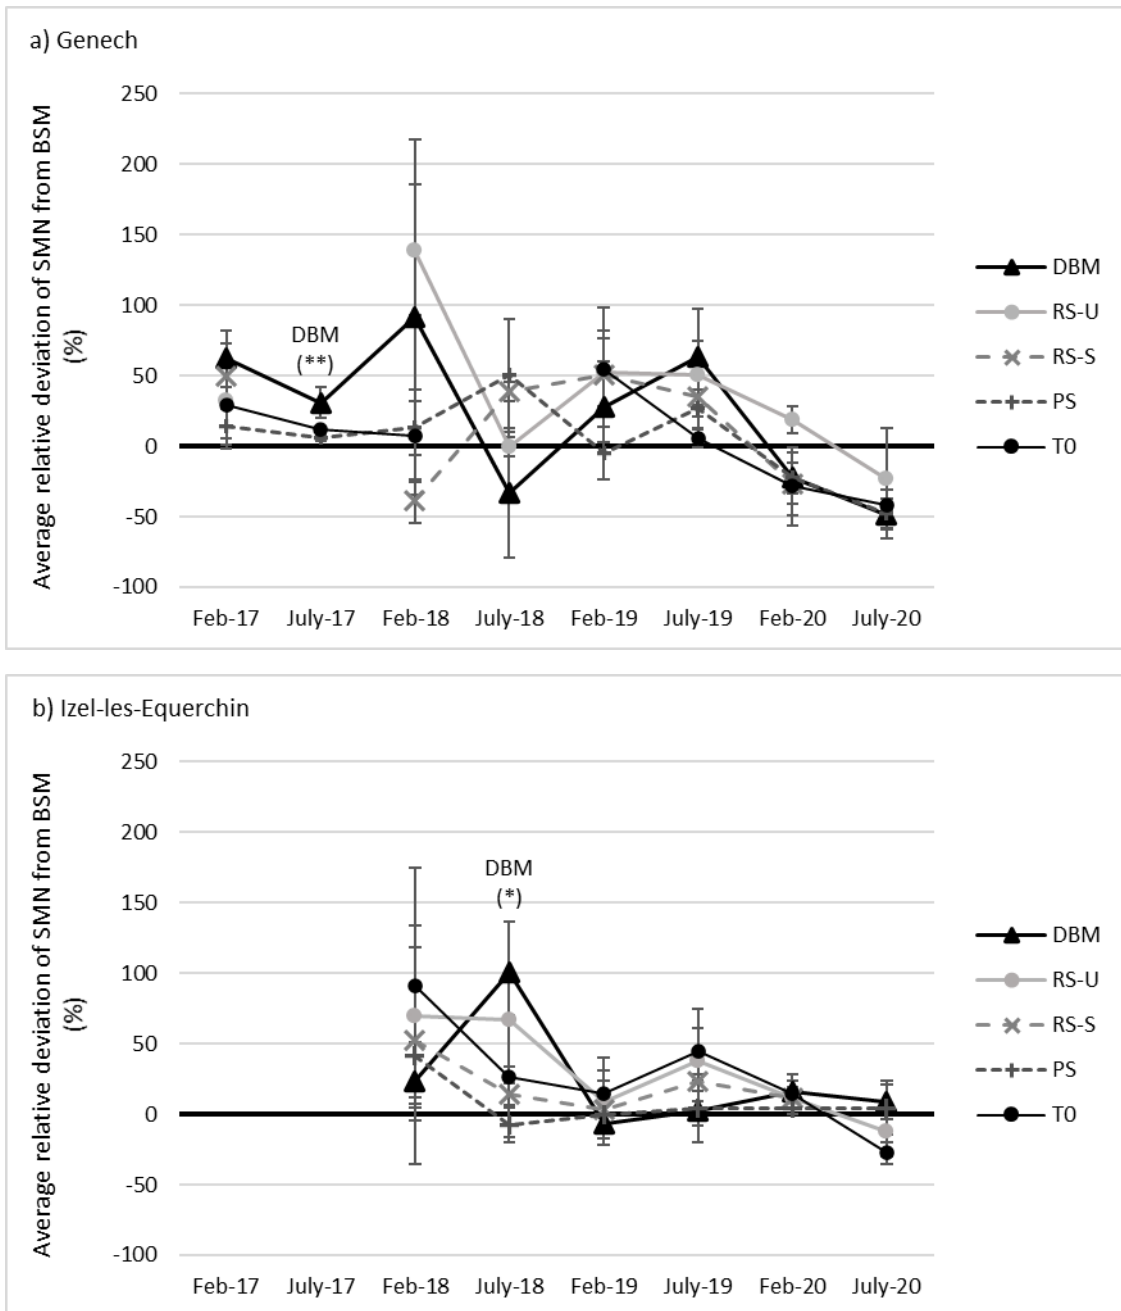


Figure 5 : Average relative deviation of soil mineral N (SMN) content measured on 90cm depth in subplots advised by DST (%) by comparison with BSM in Genech (a) and Izel-les-Equerchin (b) for 2017 to 2020. Values are means, vertical bars are standard errors. Stars represent the results of post hoc Dunnett comparison between SMN measured in subplot advised by DST and BSM for a given date. Significance of the codes: p -value<0.01 (**) and p -value< 0.05 (*). Soil mineral N content was non-determined for TO in Genech in July-18.

At the Genech experimental site (Figure 5.a), the average relative deviation of SMN measured in subplots advised by DST were mostly positive, except in July 2020. The average relative deviation ranged from -40% in July-2020 to 42% in February 2018. The smallest deviation from BSM was obtained for PS in February 2019 (-5%) and the highest for RS-U in February 2018 (+139%). When data were analyzed date per date, a significant difference between DST and BSM was observed only in July 2017 and not in other dates. In fact, the average relative deviation of SMN in DBM treatment was significantly higher than BSM at this date.

In Izel-les-Equerchin (Figure 5.b), the average relative deviation from BSM for SMN ranged from 3% in February 2019 to 55% in February 2018. Deviations from BSM measurements were more pronounced in 2018 than in 2019 and 2020. The smallest deviation from BSM was obtained for PS in February 2019 (-1%), which was exactly the same measurement date and the same DST as the smallest deviation observed in Genech. The highest deviation was observed for DBM in July 2018 (+101%), which was the only date for which a significant difference was observed between DSTs and BSM.

Thus, for both experimental sites, DSTs' advice did not significantly increase or decrease the SMN compared to the BSM, except for DBM, particularly at harvest period (2017 in Genech and 2018 in Izel-les-Equerchin). The absence of fertilization did not lead to significant lower SMN values in comparison with BSM either in Genech nor in Izel-les-Equerchin.

3.3.3. Apparent N recovery for wheat in 2018 and 2020




Figure 6 : Valorisation of the applied N fertilizer by wheat according to DSTs advices in Genech and Izel-les-Equerchin for 2018 and 2020 crop cycle. Values are means of amount of N provided by fertilizer (kg N.ha⁻¹), N uptake (kg N.ha⁻¹) and apparent nitrogen recovery (ANR; dimensionless). Vertical bars are standard errors. Stars are results of post hoc Dunnett's test for comparison between DST and BSM, Significance of the codes: p-value<0.001 (***), p-value<0.01 (**). Means without any symbol are not significantly different of BSM. No statistical analyses were carried out to compare N fertilizer rate advised by DSTs with BSM because some DSTs (DBM and RS-S) advised a unique dose for the 4 replicates and others did not (PS and RS-U).

The average values of apparent N recovery (ANR) for wheat crop were 0.55 in Genech and 0.45 in Izel-les-Equerchin. It was particularly low in Izel-les-Equerchin in 2018 with a mean value of 0.4.

In Genech experimental site, in 2018 (Figure 6.a), average ANR for BSM was 0.54, obtained for a total amount of 200 kg N.ha⁻¹. No significant difference was observed between DSTs for ANR value. In comparison with BSM, a significantly higher N uptake was noted in DBM and RS-U treatments where a higher amount of N fertilizer was applied compared to BSM (+ 36 kg N.ha⁻¹ for DBM and + 28 kg N.ha⁻¹ for RS-U). In 2020 (Figure 6.b), the value of ANR was 0.56 for BSM and no significant difference was

found with other DST. The higher amount of N fertilizer recommended by DSTs did not led to significant change in ANR (p-value=0.82) and N uptake (p-value=0.82) compared to BSM.

For the Izel-les-Equerchin experimental site, in 2018 (Figure 6.c), ANR range from 0.33 (DBM) to 0.45 (RS-S). Despite the high amount of N fertilizer applied in answer to DST advices, ranging from -3 kg N.ha⁻¹ (PS) to +80 kg N.ha⁻¹ (DBM), there was no significant difference between DSTs and BSM for the ANR parameter (p-value = 0.54) and N uptake (p-value=0.40). In 2020 (Figure 6.d), values of ANR were higher than in 2018 and ranged from 0.46 (RS-U) to 0.58 (BSM). No significant difference was found between DSTs and BSM for both ANR (p-value=0.74) and N uptake (p-value=0.14), even if the amount of the N advised rate was lower (-11 kg N.ha⁻¹ for RU-U) or higher (+71 kg N.ha⁻¹ for DBM and +34 kg N.ha⁻¹ for PS) than for BSM.

3.3.4. Diagnostic of wheat over-fertilization




Figure 7 : Relationship between the excess of mineral nitrogen observed at harvest (ΔN , kg N.ha^{-1}) and the over-fertilization calculated a posteriori (kg N.ha^{-1}), for the DSTs tested in Genech (a-b), in Izel-les-Equerchin (c-d) experimental sites and for all data combined (e). The definition of these variables is given in Eq 4 and Eq 5. Dotted lines are the linear regressions obtained between ΔN and over-fertilization: plateau line is for data where $OF < 50 \text{ kg N.ha}^{-1}$, the linear line is for data with $OF > 50 \text{ kg N.ha}^{-1}$. R^2 represents the coefficient of determination of the linear regression. A R^2 with *** is significant at $p < 0.001$ level.

The value of over-fertilization was on average 38 kg N.ha⁻¹ ranging from -35 kg N.ha⁻¹ to 140 kg N.ha⁻¹ (Figure 7.e). About 82% of the situation presented a positive value of over-fertilization and 40% exceed 50 kg N.ha⁻¹. The highest value was recorded for DBM in 2018 at the Izel-les-Equerchin experimental site (Figure 7c) and the lowest value for PS. Indeed, most negative values of over-fertilization were observed mainly for PS. Regarding the excess of mineral N in soil at harvest, the mean value was 41 kg.ha⁻¹, ranging from -20 kg.ha⁻¹ to 232 kg N.ha⁻¹. Again, the highest values were recorded for DBM and the lowest for RS-U.

For the Genech experimental site, in 2018, all fertilized treatments were over-fertilized, ranging from 15 kg N.ha⁻¹ (PS) to 62 kg N.ha⁻¹ (DBM) (Figure 7.a). On average the excess of N at harvest was 12 kg N.ha⁻¹, ranging from -2 kg N.ha⁻¹ (DBM) to 27 kg N.ha⁻¹ (PS). In 2020, on average two treatments were under-fertilized (BSM, -8 kg N.ha⁻¹ and RS-U, -27 kg N.ha⁻¹) and two over-fertilized (PS, 17 kg N.ha⁻¹ and DBM, 3 kg N.ha⁻¹) (Figure 7.b). On average, the excess of N at harvest was positive: 18 kg N.ha⁻¹ more than expected (N₂=20kg.ha⁻¹).

For the Izel-les-Equerchin experimental site, 2018 was characterized by a general high overfertilization for fertilized treatments, on average 78 kg N.ha⁻¹ (Figure 7.c). This over-fertilization ranged from 59 kg.N.ha⁻¹ (PS) to 125 kg N.ha⁻¹ (DBM). Consequently, high excesses of N were observed at harvest and values were at least equivalent to over-fertilization (PS, 59 kg N.ha⁻¹) reaching 165 kg N.ha⁻¹ (DBM). In 2020, over-fertilization ranged from -13 kg N.ha⁻¹ (BSM) to 52 kg N.ha⁻¹ (DBM), corresponding to a lower N excess (on average 3 kg N.ha⁻¹ for the fertilized treatments) compared to 2018 (Figure 7.d).

For each experimental site, the comparison of the results obtained in 2018 and 2020 highlights an effect of the year. Over-fertilization in 2018 was higher than 2020, resulting in a large excess of N observed at harvest in 2018.

When considering all data (excluding T0 treatments) a significant relationship was found between the excess of mineral N observed at harvest and the over fertilization. The data can be fitted to a plateau plus a linear model, as proposed by Beaudoin et al., (2005). The plateau is obtained for values of over-fertilization lower than 50 kg N.ha⁻¹ (Figure 7e) and correspond to ΔN of 14 kg N.ha⁻¹. Beyond 50 kg N.ha⁻¹ of over-fertilization, the ΔN was positively and significantly correlated with over-fertilization according to a linear model with a slope of 1.8 and a $R^2 = 0.42$. Among the fertilized treatments, most of the BSM-based fertilization led to an over-fertilization lower than 50 kg N.ha⁻¹ with low relationship with the N excess at harvest.

4. Discussion

Our results showed that on average, all DSTs tested on this study advised higher fertilizer N dose than BSM, often without any significant increase neither on crop yield nor on the grain quality. Every year for the same crop situation, the additional amount of N fertilizer applied beyond the dose calculated by the reference method (BSM) was DST dependent, particularly for cereals. In Genech for example, for barley, the advised dose by DBM was 78 kg N.ha⁻¹ more than the recommended dose by BSM whereas PS advised to reduce the BSM dose by 10 kg N.ha⁻¹. It was the same in 2020 for wheat in Izel-les-Equerchin where DBM recommended 80 kg N.ha⁻¹ more than BSM whereas RS-U suggested decreasing the BSM dose by -10 kg N.ha⁻¹. For rapeseed, this fluctuation in advice according to the DST used was low. These dose fluctuations may be explained by the different methods used by the different DSTs to decide the amount of N to be applied, by the difference of threshold values used to make diagnosis, and by the difference in spatial scale of diagnosis such as plant leaves scale for N-tester (Blondot et al., 2005), plant population for ImageIT and plant cover for RS-U and RS-S. Whether in situ, measurement-based DST or model-based DST, the amount of additional N fertilizer to be applied is

from a punctual diagnosis of plant N or soil N status at a given growth stage. Decisions are often made based on a threshold value which does not take into account the dynamic of the plant or soil N status in early future stages. For instance, our RS-U DST for wheat in 2018 in Genech advised to add 28 kg N.ha⁻¹ based on a diagnosis of plant N stress, whereas the BSM dose reached the same yield and grain quality at the harvest, without additional amounts of N, despite the N stress diagnosed by this DST. This result raises the question about the non-consideration by DST (i) of the plant or soil N status evolution with time in the decision of N fertilization, and (ii) of the ability of plants to valorise the additional N supply. Indeed, soil or plant N status evolves with time according to climatic conditions and can positively affect the trajectory of plant N stress. In addition, if all favourable climatic conditions are not met, the plant's ability to valorise the N could be reduced. According to Jeuffroy and Bouchard (1999), a deficiency of N at the beginning of spring is not detrimental at harvest if in the month before flowering the nutrition level is not limited. These tolerable N deficiencies may explain why, without the modulation of the last input, BSM did not show significantly different harvest performance than DSTs. In addition, the date of N status estimation will also have an effect. Crop N demand is strongly dependant on temporal factors (Diacono et al., 2013), therefore in order to avoid bad N fertilization advice, N status measures had to be taken close to the N application, to be able to perform real time N management. For this purpose, PS sensing tools are more suitable, as the farmer can use them independently. On the contrary, RS-S and RS-U measurements are less flexible, as the measurements' dates are dependent on weather conditions, satellite revolution for RS-S and availability of the RS-U provider (Späti et al., 2021). This explains why PS was the only DST that enables a significant better performance in 2020 compared to BSM. In comparison with regional wheat, barley and rapeseed crop yields (Draaf 2017, 2018, 2019, 2020), values observed on this study are slightly higher than the regional average, as well as the amount of applied fertilizer N. Average yields were respectively 5.9 Mg.ha⁻¹ for barley in 2017, 8.7 Mg.ha⁻¹ for wheat in 2018, 3.6 Mg.ha⁻¹ for rapeseed in 2019, and 9.5 Mg.ha⁻¹ for wheat in 2020. The protein content of wheat was higher in 2018 than in 2020 but the yield was also lower in 2018 than 2020. In view of the fluctuation of N fertilizer advice according to the DST used and the absence of significant improvement either for crop yield or for grain quality, our result confirms the pertinence of the BSM method by comparison with DSTs that were supposed to correct it.

Unlike results that are often proposed in literature about the reduction of N dose by DST (Colaço and Bramley, 2018; Diacono et. al., 2013), our result showed a reverse tendency. Only 25% of the DSTs advised a dose reduction from -2% to -16% by comparison with BSM. However, as concluded by Colaço and Bramley (2018), DST-based fertilization had quite variable outcomes and it is possible that negative impacts were less documented. It is important to mention that, in contrast to our work, most studies do not compare different DST among each other but rather compare variable rate technologies (VRT) with common farmer practices (Späti et al., 2021; Colaço and Bramley, 2018). Colaço and Bramley (2018) highlighted that the relative benefits of DST-based applications depend widely on farmers practices used as reference. Due to a lack of references on good fertilization practices and the relatively low N prices during the study period, several studies compare DST advice with high N rates applied by farmers, which leads to the conclusion of significant savings. In this study, DSTs were compared with another information-based method used before the crop season, ie optimal dose calculated according to the BSM, which explains that the relative benefits are small or non-existent compared to other studies (Colaço and Bramley, 2018).

Our result about the apparent N recovery (ANR) showed that, in the agropedological conditions of Genech and Izel-les-Equerchin, N recovery by wheat was low compared to values usually found in the literature (Limaux, 1999a, Cohan et al., 2018), and no significant differences were observed between DSTs and BSM. However, our values are consistent with those proposed by Grills et al. (1997) on chalk

soil in England. The lack of significant differences for ANR between DSTs explains why, despite high differences between N fertilizer rates, few significant impacts on crop yield and quality were observed. In 2020, the conditions were more favourable to N uptake, resulting in higher ANR in Izel-les-Equerchin compared to 2018 (0.42 for BSM in 2018 versus 0.59 in 2020). For Genech, differences between 2018 and 2020 were less pronounced (0.54 for BSM in 2018 versus 0.56 in 2020). Studies on ANR variations reported that this parameter may be explained by crop growth rate and crop nutrition status at the fertilizer N application, the climatic condition in the days after N application, the soil richness in mineral N, soil parameters, the form and the application of fertilizer (Limaux, 1999 a; Limaux, 1999 b; Collin 2012). Comparison between 2018 and 2020 results confirms that N fertilization effects varied widely depending on environmental conditions (Ferrante et al., 2017; Samborski et al., 2009). Some studies highlight the importance of rain during a short period right after N applications (Bouthier, 1997 in Cohan et al., 2018), while temperature and rainfall also affected soil N mineralization (Tremblay et al., 2012). The ANR results obtained in 2018 illustrate the lack of weather conditions consideration in DST advice, particularly in Izel-les-Equerchin. Indeed, due to the late sowing date in Izel-les-Equerchin in 2018, the last N fertilizer dose, which differed between the DSTs, was made early June (08/06/2018), ie before a very dry period (only 7.7mm in June versus 64.6 mm for average value of rainfall at this period). This explains the low ANR observed in Izel-les-Equerchin, and the trend observed: the higher the N applied, the lower the recovery by crops. For Genech, the additional 28 kg N.ha⁻¹ advised by RS-U, applied on 17/05/2018 (before 75 mm rain by the end of May 2018), have enabled the best ANR (ANR RS-U=0.59) to be reached. But for DBM, which modulates N-fertilizer in rate and date (last input on 28/05/2018), the additional 36 kg N.ha⁻¹ was less absorbed compared to RS-U (ANR DBM=0.57). Therefore, the dynamic model which is more accurate to advice optimal splitting of N application (Meynard et al., 2002), did not lead to a better valorisation of the inputs. These results confirmed thus that the absence or poor consideration of weather conditions limits the successful use of crop N status measurement for N recommendations (Samborski et al., 2009). It was also shown that ANR increases systematically with the date of fertilizer N application at the beginning (Machet et al., 1987), which is why the amount of fertilizer N applied at second application are high. However, it decreases at the end of crop growth so that a late nitrogen supply cannot always be valorised correctly by the crop.

In the field, the excess of N fertilizer advised by DST compared to BSM and the low N recovery led to an over-fertilization, more pronounced in 2018 than 2020. In 2018, for both experimental sites, all fertilized treatments were over-fertilized, unlike in 2020 where only DBM at Izel-les-Equerchin and PS at Genech were overfertilized, and to a lesser extent compared to 2018. This over-fertilization led to values of SMN content at harvest higher than values expected by national references (Comifer, 2013). This was especially pronounced in Izel-les-Equerchin in 2018, as the higher the advised fertilizer rate, the worse the recovery by the crop. By studying the evolution of SMN content at 90 cm depth on BSM, the SMN raise between end of winter and harvest is mainly due to variations in the upper's layers. These variations were significant for the Izel-les-Equerchin experimental site.

The N excess observed in the soil at harvest constitutes a potential N leachable especially if no cover and catch crop is installed during the interculture period, as in our case. For example, after rapeseed, the high N left in the soil (eg in Izel-les-Equerchin) and the autumnal mineralization of rapeseed residues left in the soil can lead to a high value of SMN at the beginning of the leaching period in November. This is why we observed a high SMN at the end of winter, after the rapeseed harvest in both sites. Indeed, according to Grizzetti et al. (2011) (in Hansen et al. (2017)) and Bibi et al. (2016), N leachable in groundwater is strongly linked to the N fertilizer amount and, in particular, to the N surplus. The soil type also has a huge influence, as a high pH and a low thickness, as in Izel-les-Equerchin, increases the risk of leaching (Bibi et al., 2016). In 2018, the presence of rapeseed after the

wheat will probably reduce the N excess before winter, which may have limited the environmental risk and lead to low and equivalent N level residues at the end of winter 2019 compared to winter 2018. Like Beaudoin et al. (2005), we also found a significant relationship between the measured excess of soil N at harvest and over fertilization ($R^2=0.42$). In our case, this relationship occurred for an over-fertilization rate higher than 50 kg N.ha^{-1} . For BSM at harvest, the average over-fertilization was often lower than 50 kg N.ha^{-1} (except in Izel-les-Equerchin in 2018, $OF=58 \text{ kg N.ha}^{-1}$), so there was less effect on N excess in the soil at harvest using BSM. These results raise the question about the environment outcomes of DSTs that should avoid these situations of over-fertilization by advising a N fertilizer rate relative to the crop N status. Finally, the SMN at harvest for microplots without fertilization were also higher than expected, except in Izel-les-Equerchin in 2020. This raises the question of the relevance of the reference used in the BSM (N_2). Even if this reference is defined according to the soil depth and texture, regional adaptations could be considered.

5. Conclusion

We compared three *in situ*, measurement-based and one model-based DST with the classic balance sheet method to pilot N fertilization over four years in North of France. Our results showed that all DSTs tested advised a higher fertilizer N dose, often without any significant increase either on crop yield or on grain quality. For the same agropedological situation, the advised N fertilizer fluctuated according to the DST used and the difference of dose with BSM reached up to 80 kg N.ha^{-1} . DSTs advised a dose reduction in only 25% of situations, from -2% to -16% in comparison to BSM. The diversity of advice by DSTs was certainly due to the diversity of methods used to make the decision, by the difference of threshold values used to make diagnosis and by the difference in spatial scale of diagnosis. In addition, our results highlight the lack of consideration of climatic conditions in near future. Indeed, we saw that the excess of fertilizer N advised by DST was under utilised by crop and led to an over-fertilization, which was more pronounced in 2018 than 2020 due to exceptionally dry conditions. This over-fertilization led to high values of soil mineral N content at harvest, higher than values expected by national references, and may contribute to increase the potential risk of leaching, especially if no cover and catch crop is installed in interculture. We showed that an over-fertilization higher than 50 kg N.ha^{-1} led to a significant excess of N in the soil at harvest but the inclusion of rapeseed crop in the rotation can contribute to reducing it. From our comparison, we conclude that BSM remained the best compromise to manage N fertilization: high crop productivity and quality can be maintained with limited overfertilization and low amounts of N remaining in the soil at harvest. These results raise questions about the environmental outcomes of DSTs that should avoid the situation of over-fertilization by advising a N fertilizer rate according to the evolution of crop N and plant N status and climatic condition. The use of more accurate models or a multi-sensors approach would improve the consideration of the plant and soil N status evolution and the ability of plant to valorise the additional N supply.

Funding: This work was supported by Agence de l'eau Artois Picardie and JUNIA

CRedit authorship contribution statement:

Bouchard M-A.: Methodology, Software, Validation, Formal analysis, Investigation, Ressources, Data Curation, Writing – Original Draft, Visualization, Supervision. **Andriamandroso A.L.H.:** Methodology, Software, Validation, Formal analysis, Investigation, Ressources, Data Curation, Writing – Review&Editing, Visualization, Supervision. **Lebourg M.:** Investigation, Data Curation. **Vandoorne B.:**

Conceptualization, Methodology, Software, Validation, Formal analysis, Investigation, Ressources, Data Curation, Writing – Review&Editing, Visualization, Supervision, Project administration, Funding acquisition. **Andrianarisoa S:** Conceptualization, Methodology, Software, Validation, Formal analysis, Investigation, Ressources, Data Curation, Writing – Review&Editing, Visualization, Supervision, Project administration, Funding acquisition.

Acknowledgments: The authors would like to thank the Institut de Genech and the Groupe Carré for their technical support during the experiments.

Conflicts of 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.

References:

- Beaudoin N., Saad J.K., Van Laethem C., Machet J.M., Maucorps J., Mary B., 2005. Nitrate leaching in intensive agriculture in Northern France: Effect of farming practices, soils and crop rotations. *Agriculture, Ecosystems and Environment*, 111, pp. 292-310. doi.org/10.1016/j.agee.2005.06.006.
- Bibi S., Saifullah, Naeem A., Dahlawi S., 2016. Environmental impacts of nitrogen use in agriculture, nitrate leaching and mitigation strategies. *Soil Science: Agricultural and Environmental Perspectives*, pp. 131-157. doi.org/10.1007/978-3-319-34451-5_6.
- Blondlot A., Gate P., Poilvé H., 2005. Providing operational nitrogen recommendations to farmers using satellite imagery. In: Stafford JV (ed) *Precision agriculture*. Uppsala, Sweden, pp 345–352.
- Cohan J.P., Soenen B., Le Souder C., Vericel G., Laurent F.. Improving nitrogen use efficiency in wheat: recent progress and prospects in France. In: PHLOEME – First biennials of cereal innovation, Paris 24th & 25th January 2018
- Colaço A.F., Bramley R.G.V., 2018. Do crop sensors promote improved nitrogen management in grain crops? *Field Crops Research*, 218, pp. 126-140. doi.org/10.1016/j.fcr.2018.01.007.
- Collin F. 2012., Modélisation du coefficient apparent d'utilisation de l'azote issu d'un engrais minéral apporté sur blé tendre d'hiver. MFE ARVALIS-AgroCampus Ouest, 76p
- COMIFER, 2013. Calcul de la fertilisation azotée. Guide méthodologique pour l'établissement des prescriptions locales. Cultures annuelles et prairies. Available online: http://www.comifer.asso.fr/images/publications/brochures/BROCHURE_AZOTE_20130705eb.pdf (last accessed on 08/04/2021)
- Degan F. Enquête nationale "fertilisation azotée": des pratiques plus performantes et efficaces. 2019. *Perspectives agricoles*, 463.
- Diacono M., Rubino P., Montemurro F., 2013. Precision nitrogen management of wheat. A review. *Agronomy for Sustainable Development*, 33, pp. 219–241. doi.org/10.1007/s13593-012-0111z
- Draaf. 2017. Mémento 2017-production végétales. Available online: https://draaf.hauts-de-france.agriculture.gouv.fr/IMG/pdf/memento_2017_les_productions_vegetales_cle86bf6f.pdf (last accessed on 26/01/2022)
- Draaf. 2018. Mémento 2018-production végétales. Available online: https://draaf.hauts-de-france.agriculture.gouv.fr/IMG/pdf/Memento2018-Productions-vegetales_cle846ca7.pdf (last accessed on 26/01/2022)
- Draaf. 2019. Mémento 2019-production végétales. Available online: https://draaf.hauts-de-france.agriculture.gouv.fr/IMG/pdf/Memento2019-Productions-vegetales_cle8b7cce.pdf (last accessed on 26/01/2022)
- Draaf. 2020. Mémento 2020-production végétales. Available online: https://draaf.hauts-de-france.agriculture.gouv.fr/IMG/pdf/Memento2020-Productions-vegetales_cle8b64ff.pdf (last accessed on 26/01/2022)

- FAO. 2014. World Reference Base for soil resources WRB, international soil classification system for naming soils and creating legends for soil maps. Available online: <https://www.fao.org/3/i3794en/i3794en.pdf> (last accessed on 26/01/2022)
- Ferrante A., Cartelle J., Savin R., Slafer G., 2017. Yield determination, interplay between major components and yield stability in a traditional and a contemporary wheat across a wide range of environments. *Field Crops Research*, 203, pp. 114-127. doi.org/10.1016/j.fcr.2016.12.028
- Geypens M., Vandendriessche, H., Bries, J., 1994. Experience with a Nitrogen-Index expert system: a powerful tool in nitrogen recommendation. *Soil Science and Plant Analysis*, 25 (9&10), pp. 1223-1238. doi.org/10.1080/00103629409369111.
- Grills J.P., Webb J., Dyer C.J., 1997. Seasonal variation in response of winter cereals to nitrogen fertilization and apparent recovery of fertilizer nitrogen on chalk soils in Southern England. *Journal of Agriculture Science, Cambridge*, 128, pp. 251-262.
- Hansen B., Thorling L., Schullehner J., Termansen M., Dalgaard T., 2017. Groundwater nitrate response to sustainable nitrogen management. *Scientific Reports*, 7, 8566. doi.org/10.1038/s41598-017-07147-2.
- Hothorn T., Bretz F., Westfall P., 2008. Simultaneous inference in general parametric models. *Biometrical Journal*, 50(3), pp. 346–363. doi.org/10.1002/bimj.200810425.
- Jeuffroy M.-H., Bouchard C., 1999. Intensity and duration of nitrogen deficiency on wheat grain number. *Crop Science*, 39, pp. 1385-1393.
- Lemaire G., 2019. Une nouvelle approche de la fertilisation des cultures. *Agronomie, Environnement & Sociétés*, Association Française d’Agronomie (Afa), 9.
- Li F., Miao Y., Zhang F., Cui Z., Li R., Chen X., 2009. In-season optical sensing improves nitrogen-use efficiency for winter wheat. *Soil Science Society of America Journal*, 73(5), pp. 1566-1574.
- Limaux F., 1999a. Modélisation des besoins du blé en azote, de la fourniture du sol et de l’utilisation de l’engrais : application au raisonnement de la fertilisation en Lorraine [Thèse de doctorat de l'Institut National Polytechnique de Lorraine Spécialité "Sciences Agronomiques"]
- Limaux F., 1999b. Relationship between rate of crop growth at date of fertiliser N application and fate of fertiliser N applied to winter wheat. *Plant and soil*, 214(1), pp. 49-59.
- Machet J.M., Dubrulle P., Louis P., 1990. Azobil®: a computer program for fertilizer N recommendations based on a predictive balance sheet method. In: Scaife A. Proceedings of the 1st Congress of the European Society of Agronomy, 5th-7th December 1990, Paris, France. Colmar, France : ESA/INRA/CEC.
- Machet J.M., Pierre D., Recous S., Remy J.C., 1987. Signification du coefficient réel d'utilisation et conséquences pour la fertilisation azotée des cultures. *Comptes Rendus de l'Académie d'Agriculture de France*, 73 (3), pp.39-55.
- Meynard J.M., Cerf M., Guichard L., Jeuffroy M.H., Makowsky D., 2002. Which decision support tools for the environmental management of nitrogen? *Agronomie*, 22, pp. 817-829. doi.org/10.1051/agro:2002064.
- Meynard J.M., Jeuffroy M.H., 2019. 50 ans de méthode du bilan : progrès passés et limites actuelles (50 years with the balance-sheet method : past progress and current limits). *Agronomie, Environnement & Sociétés*, Association Française d’Agronomie (Afa), 9.

- Meynard J.M., Justes E., Machet J.M., Recous S., 1997. Fertilisation azotée des cultures annuelles de plein champ. In: Lemaire, G., Nicolardot, B. (Eds.), *Maîtrise de l'azote dans les agrosystèmes*. INRA Editions, Paris, pp. 183–200.
- Ministry of Agriculture, Food and Forestry., 2015. Inventory and analysis of decision support tools and management of N fertilization. Rapport, 81 p. Online, available on: https://comifer.asso.fr/images/bilan-azote/outils-de-pilotage/2016_Rapport_OAD_Pilotage_Ferti_SCE.pdf (last accessed on 26/01/2022)
- Pinheiro J., Bates D., DebRoy S., Sarkar D. R Core Team., 2021. nlme: Linear and Nonlinear Mixed Effects Models. R package version 3.1-153. Available online: <https://CRAN.Rproject.org/package=nlme> (last accessed on 26/01/2022)
- Ravier C., Meynard J.M., Cohan J.P., Gate P., Jeuffroy M.H., 2017. Early nitrogen deficiencies favor high yield, grain protein content and N use efficiency in wheat. *European Journal of Agronomy*, 89, pp. 16-24. doi.org/10.1016/j.eja.2017.06.002
- Ravier C., Jeuffroy M.H., Meynard J.M., 2016. Mismatch between a science-based decision tool and its use: The case of the balance-sheet method for nitrogen fertilization in France. *NJAS Wageningen J. Life Sci.*, 79, pp. 31–40. doi.org/10.1016/j.njas.2016.10.001.
- Samborski S.M., Tremblay N., Fallon E., 2009. Strategies to make use of plant sensors-based diagnostic information for nitrogen recommendations. *Agronomy Journal*, 101(4), pp. 800-816. doi.org/10.2134/agronj2008.0162Rx
- Späti K., Huber R., Finger R., 2021. Benefits of increasing information accuracy in variable rate technologies. *ecological economics*, 185(8). doi.org/10.1016/j.ecolecon.2021.107047
- Tremblay N., Bouroubi Y.M., Bélec C., Mullen R.W., Kitchen N.R., Thomason W.E., Ebelhar S., Mengel D.B., Raun W.R., Francis D.D., Vories E.D., Ortiz-Monasterio I., 2012. Corn response to nitrogen is influenced by soil texture and weather. *Agronomy Journal*, 104(6), pp. 1658-1671. doi.org/10.2134/agronj2012.0184
- Vandendriessche H., Bries J., Geypens M., 1996. Experience with fertilizer expert systems for balanced fertilizer recommendations. *Soil Science and Plant Analysis*, 27 (5-8), pp. 1199-1209. doi.org/10.1080/00103629609369626.
- Zadoks J.C., Chang T., Konzak C.F., 1974. A decimal code for the growth stages of cereals. *Weed Research*, 14, pp. 415-421.

Discussion générale et perspectives

Actuellement, un nouveau paradigme de pilotage de la fertilisation azotée émerge et propose de s'affranchir de la méthode du bilan pour se baser sur la plante comme indicateur de son niveau de nutrition (Ravier et al., 2018). Pour cela, l'indice de nutrition azotée (INN) présente un intérêt particulier puisqu'il est spécifique et sensible aux changements de nutrition azotée (Lemaire et al., 2008). En tenant compte à la fois de la biomasse et de la concentration en N, il peut être comparé à une référence afin d'identifier une éventuelle carence en N. Ceci rend cet indice très adapté à une utilisation dans le cadre d'un pilotage dynamique de la fertilisation azotée (Chen, 2015 ; Lemaire, 2019).

Dans ce contexte, les estimations indirectes du statut azoté par proxi- ou télédétection sont intéressantes (Lemaire, 2019), permettant des mesures rapides, non destructives et répétables en cours de croissance (Chen, 2015). Ainsi, le travail réalisé durant cette thèse a porté **sur le suivi et l'évaluation non-destructive de l'INN du blé tendre en cours de campagne dans le but d'intégrer par la suite ces connaissances dans une démarche de pilotage dynamique de la fertilisation azotée**. Étant donné sa flexibilité d'utilisation et sa proximité du couvert végétal, le drone présente un intérêt particulier pour suivre le statut azoté d'une culture en cours de campagne car les caméras qu'il peut transporter offrent, dans ce contexte, une très bonne résolution spatiale des images collectées (Zheng et al., 2018 ; Quemada et al., 2019). Il a donc été retenu dans cette étude pour suivre l'INN par télédétection.

Cette thèse a été construite en deux volets ; un premier, décliné en quatre chapitres, axé sur l'amélioration du suivi de l'INN par proxi- et télédétection et sur l'étude de la mise en place des composantes de rendement. Pour cela, un suivi de trois essais présentant un gradient de fertilisation a été réalisé à la fois sur le terrain par mesures destructives et l'utilisation d'un capteur optique foliaire (Dualix, Force A, Orsay), mais aussi au moyen de caméras multispectrales montées sur drone. Un second volet a porté sur le suivi des performances agronomiques et environnementales de différents outils d'aide à la décision (OAD) proposés actuellement aux agriculteurs pour piloter la fertilisation azotée.

Cette dernière section vise à discuter des résultats obtenus dans les 5 chapitres précédents au travers des réponses apportées à trois questions transversales. Dans un premier temps, la discussion portera sur l'efficacité de la télédétection pour suivre l'INN à partir d'images prises par un drone. Dans un second temps, des pistes d'amélioration seront proposées et évaluées. Enfin, une discussion finale visera à recouper les informations des 2 volets d'étude dans le but de traduire l'ensemble des résultats obtenus dans une proposition de méthode de pilotage dynamique de la fertilisation azotée, à tester ultérieurement.

1. La télédétection permet-elle de mesurer efficacement l'INN ?

Une large gamme d'indices de végétation (IV), basés sur des mesures faites par drone, ont déjà été développés et étudiés pour suivre le statut azoté du blé. Des corrélations paramétriques ont été faites entre les IV et différents paramètres liés au statut azoté du blé :

- la concentration en N des feuilles (%N) (Liu et al., 2016 ; Zheng et al., 2018 ; Niu et al., 2019),
- le contenu en N des feuilles (g par unité de surface) (Yao et al., 2015),
- la concentration en N dans la biomasse aérienne (%N) (Quemada et al., 2019; Gordillo-Salinas et al., 2021; Li et al., 2014 ; Chen, 2015),
- le contenu en N dans la biomasse aérienne (g par unité de surface) (Bao et al., 2013 ; Quemada et al., 2019 ; Yang et al., 2019 ; Argento et al., 2020)
- l'INN (Argento et al., 2020 ; Chen, 2015 ; Gordillo-Salinas et al., 2021).

Plusieurs études mettent en avant la difficulté d’avoir un seul et unique IV capable de suivre l’évolution du statut azoté dans des situations variées de conditions de mesures, variétés, stades de croissance, etc. (Chen, 2015 ; Zheng et al., 2018 ; Liu et al., 2016).

Ce constat est d’ailleurs confirmé par les résultats obtenus dans le **chapitre 1** où, en 2019, 14 IV connus avaient été calculés à partir de mesures prises par une caméra multispectrale Sequoia (Parrot, Paris, France), embarquée sur un drone (Phantom 4, DJI, Shenzhen, Chine), enregistrant des images dans 4 longueurs d’onde : vert 550nm (± 40 nm), rouge 660nm (± 40 nm), Red Edge 735nm (± 10 nm) et proche infrarouge (NIR) 790nm (± 40 nm). Les corrélations obtenues entre ces 14 IV et l’INN étaient moyennes avec des coefficients de détermination (R^2) atteignant tout au plus 0.58 au stade Z30 (épis 1cm) pour les IV GRVI (550-790nm) et MCARI/OSAVI (550-660-790nm) (Zadoks et al., 1974). Au stade Z39 (dernière feuille étalée), les corrélations étaient moins bonnes, le R^2 atteignant 0.47 pour SR (660-790nm). En outre, les formulations des IV et les 4 longueurs d’onde considérées n’ont pas permis de discriminer les IV entre eux, c’est-à-dire qu’il n’a pas été possible de ressortir un IV comme étant le plus performant.

Afin d’améliorer le suivi du statut azoté à partir d’images prises par un drone, 2 pistes ont été évaluées dans les **chapitres 1 et 2**, à savoir (1.1) l’exploration de nouvelles gammes de longueurs d’onde et (1.2) l’étude de modèles de régression non-paramétriques. La démarche suivie est synthétisée dans la figure 1 et détaillée dans la partie suivante.




Figure 1 : schéma du raisonnement suivi dans le but d'améliorer la prédiction de l'INN en élargissant la gamme de longueurs d'onde étudiées et en évaluant le potentiel de prédiction de modèles non-paramétriques (méthodologie utilisée dans les chapitres 1 et 2) (INN : indice de nutrition azotée, NBI : nitrogen balance index, IV : indice de végétation, Ridge : régression pénalisée de Ridge, PLS : régression par les moindres carrés partiels, PCR : régression sur les composantes principales et RF : forêts aléatoires)

1.1. Exploration de nouvelles gammes de longueurs d'onde

Dès 2020, l'utilisation d'une caméra multispectrale (Caméra Kernel, Mapir, San Diego), dont les filtres de chaque lentille sont modulables, montée sur drone (M1agri, ADT drone, Soissons, France) a permis d'explorer une plus vaste gamme de 15 longueurs d'onde : 405nm (± 50 nm), 450nm (± 50 nm), 490nm (± 75 nm), 518nm (± 50 nm), 550nm (± 50 nm), 590nm (± 50 nm), 615nm (± 75 nm), 632nm (± 50 nm), 650nm (± 50 nm), 685nm (± 50 nm), 725nm (± 50 nm), 780nm (± 50 nm), 808nm (± 50 nm), 850nm (± 100 nm) et 940nm (± 200 nm). L'idée initiale était d'en identifier certaines qui seraient plus sensibles aux changements de statut azoté. Cette démarche est innovante dans le sens où les caméras montées sur drone ne disposent, dans la majeure partie des cas, que d'un nombre limité d'objectifs. Ainsi, cette approche par exploration de nombreuses longueurs d'onde a, jusqu'à aujourd'hui, été investiguée en utilisant des caméras hyperspectrales qui sont majoritairement utilisées en proxidétection et donc plus difficilement déployables à grande échelle (Yao et al., 2015 ; Hansen et Schjoerring, 2003). En effet, dans leur synthèse de 125 études portant sur la prédiction du statut azoté à partir d'images hyperspectrales, Berger et al. (2020) ont relevé que 76% des études sont basées sur des mesures faites par proxidétection tandis que 6% seulement des caméras hyperspectrales sont embarquées sur drone. Concernant les expérimentations menées dans cette thèse, des mesures de réflectance du couvert ont été prises en 2020 et en 2021 en suivant des essais présentant respectivement 13 et 20 stratégies de fertilisation. Les stades Z32 (2 nœuds) et Z39 ont été suivis en 2020, et Z32 et Z45 (gonflement) en 2021.

Les résultats obtenus montrent que l'étude de chaque longueur d'onde, individuellement, n'est pas pertinente et qu'aucune ne ressortait comme particulièrement corrélée au statut azoté (**chapitre 1**). Contrairement aux IV qui sont développés pour être plus sensibles à un paramètre de la culture, une valeur brute de réflectance n'est, en effet, pas assez spécifique et semble plus sensible aux conditions de mesure (Haboudane et al., 2004, Yang et al., 2019).

Les mesures de réflectance ont donc été combinées entre elles en utilisant la formulation de 8 IV (**chapitre 2**). Le fait d'avoir des mesures dans 15 longueurs d'onde nous a permis de tester différentes combinaisons pour chaque IV ; une « couleur » utilisée dans une formule pouvant correspondre à plusieurs longueurs d'onde parmi les 15 mesurées (**chapitre 2**). En pratique, cela a représenté 248 combinaisons testées. Par stade et par année, les combinaisons minimisant le RMSE étaient : GNDVI en 2020, combinant 550-940nm à Z32 (coefficient de détermination, $R^2=0.36$) et 615-780nm à Z39 ($R^2=0.56$), NG en 2021, combinant 550-940nm à Z32 ($R^2=0.47$) et 590-808nm à Z45 ($R^2=0.48$).

Si les résultats sont encourageants, les combinaisons calculées au stade Z32, quelle que soit l'année, n'ont pas permis d'améliorer la capacité de prédiction de l'INN par rapports aux IV calculés à partir d'images prises par une caméra Sequoia (4 longueurs d'onde enregistrées par survol) au stade Z30 en 2019. Cependant, parmi les enseignements à tirer de cette partie, il apparaît, pour les 3 années étudiées, que le vert (550nm) et le NIR (début du NIR, 790nm en 2019 et 940nm en 2020 et 2021) ressortent comme des longueurs d'onde d'intérêt en début d'élongation (stades Z30 et Z32) pour le calcul des IV. Cette tendance est intéressante étant donné que les IV combinant le rouge ou le RedEdge avec du NIR, comme le NDVI, le RDVI, le SAVI ou le NDRE, sont pourtant jusqu'à aujourd'hui les plus utilisés dans la littérature pour estimer le statut azoté et sont souvent rapportés comme étant les plus performants (Zheng et al., 2018 ; Argento et al., 2020). L'intérêt relevé dans cette étude pour la longueur d'onde 550nm peut s'expliquer par le fait que celle-ci correspond à la longueur d'onde dans le visible pour laquelle la réflectance varie le plus en réponse à une variation de taux de chlorophylles, que l'on sait directement lié au statut azoté (Hatfield et al., 2008). D'après la synthèse réalisée par Padilla et al. (2018), les IV combinant le vert et le RedEdge sont plus appropriés pour suivre le statut

azoté que ceux basés sur la réflectance dans le rouge. Ils sont en effet décrits comme sensibles à toute la gamme de teneur en chlorophylles, moins sensibles à la saturation en conditions d'excès d'N et seraient également plus stables par rapport aux variations des conditions de mesure (De Souza et al., 2021). Ces 2 derniers points sont particulièrement importants à garder en tête pour la suite au moment de réfléchir à la mise en place d'une démarche de pilotage dynamique. Il est en effet essentiel de pouvoir estimer un déficit ou un excès d'N tout en ayant une mesure répétable en saison et entre les saisons.

Contrairement au stade Z32, le calcul de nouvelles combinaisons aux stades Z39 et Z45 a permis d'améliorer légèrement le R^2 par rapport aux indices calculés en 2019 à partir d'images prises par la caméra Sequoia. Pour rappel, en 2019 à Z39, l'IV le performant était calculé en combinant le rouge (660nm) et le début du NIR (790nm). Les résultats obtenus en 2020 et 2021 ont confirmé l'intérêt de l'utilisation du début du NIR (780nm en 2020 et 808nm en 2021), mais combiné à 615nm et 590nm en 2020 et 2021. Ces longueurs d'onde correspondent à la portion orange-début du rouge du spectre qui est pourtant peu utilisée dans la littérature pour suivre le statut azoté (Annexe 1). Il semblerait donc que les combinaisons début du NIR-orange soient plus sensibles que les IV utilisant le vert ou le rouge en association au NIR, en fin d'élongation-gonflement.

Malgré l'exploration de nouvelles longueurs d'onde en 2020 et 2021, la capacité des IV testés à suivre le statut azoté du blé à ce stade reste toutefois moyenne. Les meilleures performances ont été obtenues : à Z32 pour la meilleure combinaison NG 550-940nm en 2021 ($R^2=0.47$) et à Z39 pour GNDVI 615-780nm en 2020 ($R^2=0.56$). Par rapport au **chapitre 1**, les performances n'ont été améliorées qu'en fin d'élongation-gonflement.

Différentes solutions peuvent être testées afin d'améliorer le suivi de l'INN par télédétection. Jiang et al. (2019) mettent en évidence que la plupart des études portent sur des applications pratiques des images prises par drone, mais peu étudient la précision des étapes de prétraitement des données. Or ces étapes, au nombre de 5 (correction du bruit, correction du vignettage, correction de la distorsion de l'objectif, renseignement de la longueur d'onde pour chaque objectif, correction radiométrique), sont essentielles pour avoir des données de qualité. L'étude de Jiang et al. (2019) a porté sur l'évaluation (i) de chaque étape de prétraitement des images prises par caméra (Mini-MCA6, Tetracam, Chatsworth, USA) et (ii) de différentes méthodes d'étalonnage. La caméra modulable Kernel utilisé dans ce travail étant récente (mise sur le marché en 2017) (MAPIR, 2022), peu de références existent sur la qualité du prétraitement des images prises par cette caméra. Toutefois, plusieurs études mettent en évidence la qualité obtenue à la suite d'une calibration à partir d'images d'une mire de calibration prises en amont des vols plutôt qu'avec un capteur de rayonnement incident (Jiang et al., 2019 ; Del Pozo et al., 2014). Dans leurs travaux, Jiang et al. (2019) comparent une correction radiométrique effectuée à partir d'un capteur de lumière incidente (ILSC, light intensity sensor correction) et une relation linéaire empirique à partir d'images de mire de calibration (ELC, empirical correction). Ils mettent en évidence de meilleurs résultats avec une mire de calibration dans avec un RMSE réduit de 65.4% entre ces 2 méthodes. Une seconde piste aurait été d'utiliser des IV exprimés dans le HVB (hue, saturation, brightness) qui se basent sur les valeurs de teinte, saturation et luminosité, plutôt que sur la réflectance dans différentes longueurs d'onde. L'avantage de ces indices est qu'ils peuvent être calculés simplement et ne nécessitent pas de caméras complexes (Caturegli et al., 2019). Toutefois ces malgré des applications intéressantes de ces indices pour suivre le statut azoté par proxidtection (Rorie et al., 2011), ils restent très sensibles aux conditions de mesures lorsqu'elles sont réalisées par drone (Ge et al., 2021). Enfin, la caméra modulable utilisée dans ce travail présente l'intérêt et l'originalité de permettre des mesures dans 15 longueurs d'onde, la démarche retenue a donc été

d'exploiter le potentiel d'une diversité plus importante de longueurs d'onde pour améliorer la qualité de prédiction.

1.2. Etude de modèles de régression non-paramétriques

Les IV ne prennent en compte qu'un nombre limité de longueurs d'onde, n'exploitant qu'une part de l'information. Ils sont donc très spécifiques au capteur utilisé et aux conditions de mesures (site, environnement, stade, variété, etc.) (Berger et al., 2020). Afin de prendre en compte plus d'informations, une seconde piste explorée dans ce travail a porté sur l'étude des modèles de prédiction non-paramétriques. Par opposition aux modèles paramétriques, qui se basent sur une relation connue entre différentes variables, les modèles non-paramétriques sont appropriés lorsque le prédicteur le plus adapté est inconnu et qu'il n'existe pas de fonction d'estimation connue. Ces modèles se basent sur le jeu de données mesurées pour construire le modèle d'estimation. Ils sont adéquats lorsque le nombre de variables d'entrée est conséquent, comme c'est souvent le cas pour les données issues de la télédétection. En prenant en compte plusieurs IV à la fois, ils devraient être moins spécifiques que les IV seuls et devraient permettre d'augmenter le nombre de longueurs d'onde explorées. Ceci comblerait alors les limites identifiées précédemment et devrait ainsi permettre d'améliorer le suivi de l'INN (Zheng et al., 2018 ; Yang et al., 2019 ; Li et al., 2014 ; Yao et al., 2015 ; Liu et al., 2016). Le **chapitre 2** a porté sur la construction et l'évaluation de 4 modèles non-paramétriques: la régression pénalisée de Ridge, la régression par les moindres carrés partiels (PLS), la régression sur les composantes principales (PCR) et les forêts aléatoires (RF).

La Figure 2 schématise le processus de construction et de validation des modèles non paramétriques, ceux-ci ont été construits afin de prédire une variable d'intérêt, ici l'INN (Figure 2, Y), à partir d'un ensemble de variables explicatives (Figure 2, X), dans notre cas les différentes combinaisons de longueurs d'onde. Dans un premier temps, les jeux de données entiers ont été divisés en deux, par année et par stade : 75% pour l'entraînement des modèles et 25% pour leur validation. Dans le but d'avoir un modèle applicable sur le terrain dans le futur, il ne paraissait pas pertinent de prendre en compte la totalité des 248 combinaisons calculées dans la construction des modèles. Ainsi, les variables d'entrée des modèles ont été sélectionnées parmi les 248 combinaisons, en se basant sur le RMSE calculé à la suite des régressions linéaires individuelles faites entre chaque combinaison et l'INN (figure 1). Deux méthodes de sélection ont été testées, une première méthode a consisté à sélectionner la combinaison minimisant le RMSE pour chacune des huit formulations d'IV testées. Toutefois, étant donné que toutes les formulations ne paraissaient pas pertinentes pour prédire l'INN (**chapitre 2**), une seconde méthode s'est basée sur un seuil afin de sélectionner les combinaisons qui minimisent le RMSE quel que soit la formulation utilisée.

Les modèles ont ensuite été construits et entraînés sur les 75% du jeu de données d'entraînement prévus à cet effet. A cette étape, les paramètres des modèles sont ajustés à l'ensemble du jeu de données d'entraînement. Une première validation a ensuite été réalisée par validation croisée, c'est-à-dire en utilisant le même jeu de données que pour la phase d'entraînement. Le jeu de données est divisé en sous échantillons, un de ces sous échantillons est mis de côté pour valider le modèle tandis que les échantillons restants sont utilisés pour ajuster le modèle. Cette opération est répétée plusieurs fois en sélectionnant d'autres sous-échantillons. Dans ce travail la méthode de validation croisée utilisée a été une « leave-one-out-cross-validation » c'est-à-dire que chaque sous-échantillon correspond à un individu, le coefficient de détermination (R^2) calculé à cette étape a été nommé R^2 entraînement (figure 2). Les modèles ont ensuite été validés avec le jeu de données de validation prévu pour cela (25% mis de côté avant entraînement du modèle), permettant d'estimer la qualité de prédiction du modèle par le calcul du R^2 validation. Enfin, les modèles ont été validés avec un jeu de

données indépendant, dans le cas de ce travail, en utilisant le jeu de données de 2020 pour valider les modèles créés à partir du jeu de données 2021 et inversement. Le R^2 calculé a été nommé R^2_{test} .

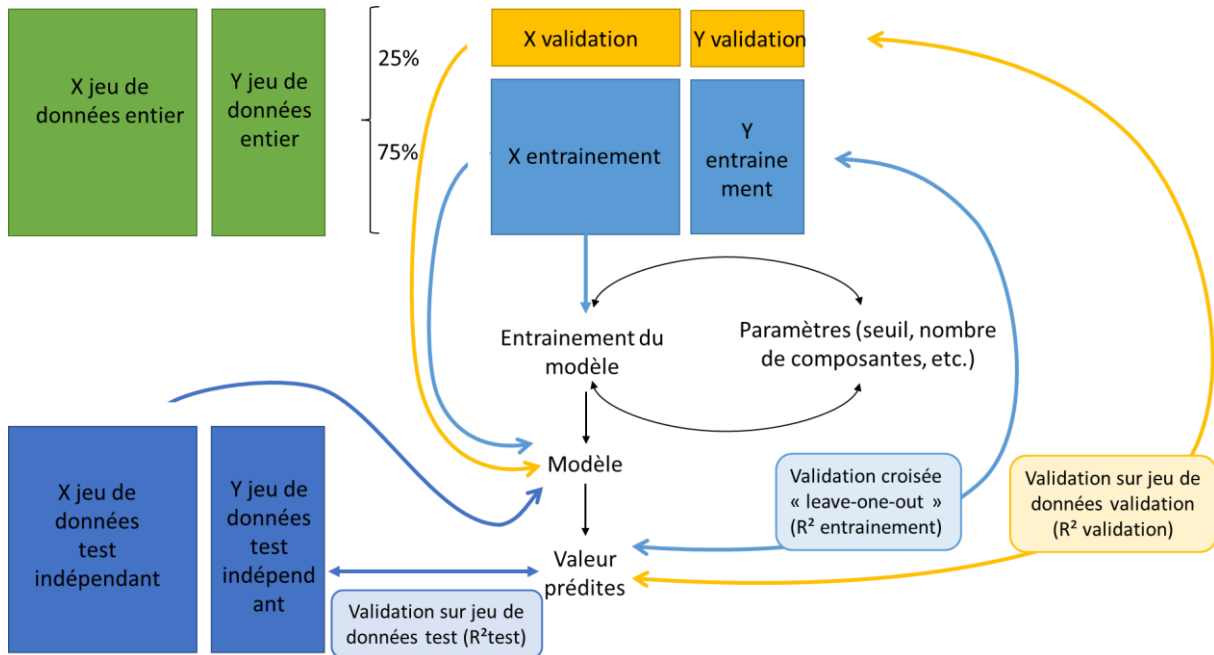


Figure 2 : schéma du processus de construction et de validation des modèles non-paramétriques. Dans le cadre de ce travail, la variable à prédire Y était l'INN et les variables explicatives X étaient les combinaisons de mesures de réflectance. Le jeu de données entier correspondait aux mesures faites à un stade pour une année donnée, ils ont successivement été utilisés, d'une part pour construire les modèles et d'autre part pour les tester les modèles construits à partir d'un autre jeu de données

De façon générale, les modèles étaient plus performants au stade Z32 qu'aux stades Z39 et Z45. Les R^2 obtenus pour les modèles testés au stade Z32 sont rappelés dans le tableau 1.

Tableau 1 : synthèse des R^2 et R^2 validation obtenus au stade Z32 en 2020 et 2021 pour les 4 modèles non-paramétriques entraînés et validés avec d'une part les combinaisons qui minimisent le RMSE par formulation d'IV et d'autre part en utilisant un RMSE qu'importe la formulation

Modèle 2020-Z32			
	R^2 entraînement	R^2 validation	Nombre de variables
Ridge- meilleure combinaison par IV	0.36	0.89	8
PCR- meilleure combinaison par IV	0.35	0.82	8
PLS- meilleure combinaison par IV	0.35	0.82	8
RF- meilleure combinaison par IV	0.86	0.55	8
Ridge- avec RMSE seuil	0.37	0.87	42
PCR- avec RMSE seuil	0.40	0.74	42
PLS- avec RMSE seuil	0.40	0.72	42
RF- avec RMSE seuil	0.90	0.75	42
Modèle 2021-Z32			
	R^2 entraînement	R^2 validation	Nombre de variables
Ridge- meilleure combinaison par IV	0.51	0.64	8
PCR- meilleure combinaison par IV	0.53	0.72	8
PLS- meilleure combinaison par IV	0.53	0.72	8
RF- meilleure combinaison par IV	0.86	0.74	8
Ridge- avec RMSE seuil	0.44	0.71	29
PCR- avec RMSE seuil	0.46	0.59	29
PLS- avec RMSE seuil	0.43	0.60	29
RF- avec RMSE seuil	0.88	0.78	29

Les modèles RF ont permis d'atteindre de très bons R^2 lors de la phase d'entraînement et de validation mais ne semblent pas adaptés aux données utilisées car un surajustement du modèle est systématiquement remarqué en comparant le R^2 entraînement obtenu par validation croisée et celui obtenu sur le jeu de données de validation.

Les modèles de Ridge, PLS et PCR présentent de bonnes performances. En fonction des modèles, ils permettent d'obtenir un R^2 entraînement par validation croisée légèrement supérieur par rapport à la meilleure combinaison de longueurs d'onde étudiées individuellement. Au stade Z32 en 2020, ce sont les modèles de Ridge, PCR et PLS avec pour variables d'entrée les combinaisons sélectionnées en fonction d'un seuil (R^2 entraînement=0.37, 0.40 et 0.40) qui permettent d'obtenir une meilleure prédiction de l'INN par comparaison à la meilleure combinaison prise individuellement (GNDVI 550-940nm, R^2 entraînement=0.36). Au stade Z32 en 2021, la combinaison la plus performante était NG 550-940nm (R^2 entraînement=0.47), les modèles Ridge, PCR et PLS avec pour variables d'entrée les combinaisons qui minimisent le RMSE par formulation d'IV, ont permis d'améliorer la prédiction de l'INN (R^2 entraînement=0.50, 0.52 et 0.53). Toutefois, les valeurs d'INN prédites étaient plus cohérentes avec les modèles PLS et PCR qu'avec le modèle de Ridge. Ainsi, sur le jeu de données de validation, les coefficients de détermination (R^2) de validation obtenus à Z32 pour les modèles PLS et PCR atteignaient 0.82 en 0.72 en 2021 (Tableau 1). Parmi ces 2 modèles, PCR et PLS, le choix s'est porté par la suite sur les modèles PLS, dont les composantes sont définies de façon à être corrélées à la variable d'intérêt (Tenenhaus et al., 1998 in Makowski et al., 2021).

Les valeurs de R^2 évoquées ici sont cohérentes avec celles trouvées dans la littérature pour des modèles non-paramétriques basés sur des images prises par drone pour prédire le statut azoté du blé. Par exemple, Zheng et al. (2018) ont obtenu un R^2 de 0.74 par cross validation pour la prédiction de la concentration en N des feuilles (%N) avec le modèle PLS ; le modèle le plus performant dans leur cas étant le RF ($R^2=0.79$). Yang et al. (2019) obtenaient quant à eux de bons résultats pour prédire le contenu en N du couvert ($\text{kg}\cdot\text{ha}^{-1}$) avec des modèles PLS ($R^2_{\text{validation}}=0.72$), SVR (*support vector regression*) ($R^2_{\text{validation}}=0.75$) et PSO-SVR (*Particle Swarm Optimization-based Support Vector Regression model*) ($R^2_{\text{validation}}=0.80$). Dans leur cas ces meilleures performances étaient atteintes en prenant à la fois des IV et des longueurs d'onde normalisées comme variables d'entrées.

Toutefois, les comparaisons à la littérature ne sont pas toujours simples, les résultats obtenus étant dépendants des différences de résolution spatiale des mesures, des capteurs utilisés et des paramètres des modèles (Berger et al., 2020). De plus, il existe aussi une certaine incohérence dans les termes utilisés pour définir le statut azoté : la concentration en N (%N) et le contenu en N (g par unité de surface) ne sont pas toujours bien définis ce qui complexifie les comparaisons (Berger et al., 2020). Il est également intéressant de noter que certaines études présentent uniquement les R^2 entraînements obtenus par validation croisée, ce qui est insuffisant pour conclure quant à la pertinence d'un modèle car le risque de surajustement n'est alors pas considéré. Enfin, de nombreux modèles non-paramétriques sont élaborés à partir de mesures de réflectance prises par proxidéttection (Li et al., 2014 ; Hansen et Schjoerring 2003 ; Yao et al., 2015). Ces modèles permettant de prendre en compte un nombre important de variables d'entrée. La plupart des études se basent donc sur des mesures obtenues au moyen de caméras hyperspectrales majoritairement utilisées dans ces situations de proxidéttection. Or les mesures par proxidéttection sont plus précises car moins sensibles aux conditions de mesures ce qui peut expliquer les meilleurs R^2 . De plus, il est avéré que les données utilisées pour l'entraînement du modèle vont fortement influencer sa robustesse (Li et al., 2014). En effet, selon la littérature, des jeux de données contrastés, provenant d'années, de sites, de variétés et de stades différents ne doivent pas être utilisés indépendamment pour construire et valider les modèles. Il est préférable de combiner toutes les données entre elles pour améliorer la qualité de prédiction. Dans notre cas, avec seulement 2 années contrastées, combiner les mesures n'a pas permis d'améliorer la qualité de prédiction du modèle par rapport aux résultats de 2020 et 2021 considérés indépendamment.

Pour conclure cette partie, d'après les résultats obtenus en 2019 à partir de mesures prises par caméra Sequoia, les IV calculés à partir d'images prises par des caméras traditionnellement embarquées sur drone obtiennent aujourd'hui des corrélations moyennes vis-à-vis du statut azoté d'une culture donnée. L'acquisition d'une caméra multispectrale ayant des lentilles avec des filtres modulables a permis d'explorer deux pistes pour améliorer la qualité de prédiction de l'INN : améliorer la sensibilité des IV par la prise en compte de nouvelles longueurs d'onde et construire des modèles non-paramétriques prenant en compte plusieurs IV. Ces deux pistes ne se sont pas avérées pleinement concluantes. Dans le premier cas, au stade Z32, les nouvelles longueurs d'onde n'ont pas permis d'aboutir à un IV plus performant que ceux calculés classiquement. Toutefois, l'intérêt de combiner la réflectance dans le vert et le NIR s'est confirmé pour les 3 années étudiées et particulièrement en 2020 et 2021. Aux stades Z39 et Z45, en 2020 et 2021, la combinaison du début du NIR avec la réflectance mesurée dans la portion orange-début du rouge du spectre a permis d'être plus sensible que la combinaison du rouge et début du NIR calculée en 2019. Enfin, les modèles non paramétriques n'ont, quant à eux, pas permis d'améliorer significativement les performances d'évaluation du statut azoté. Ils restent toutefois une piste à explorer et à développer car ils devraient présenter l'avantage d'être moins spécifiques aux conditions de mesures que les IV seuls.

2. Malgré les limites de la télédétection, peut-on évaluer efficacement le statut azoté du blé de façon non destructive ?

2.1. Exploration du potentiel d'une approche combinée utilisant la proxi- et télédétection dans le but d'obtenir un modèle de prédiction de l'INN opérationnel

À la suite de l'entraînement et de la validation de 4 modèles de prédiction non paramétriques dans le **chapitre 2**, le **chapitre 3** s'est recentré plus particulièrement sur le potentiel du modèle PLS. En effet, celui-ci permet d'obtenir des R^2 intermédiaires à Z32 (Tableau 1, R^2 de 0.35 à 0.53 et R^2 validation de 0.6 à 0.82 en fonction des années et variables d'entrées considérées), mais avec des valeurs cohérentes d'INN prédits. Cela confirme l'intérêt de ce modèle pour étudier les données issues de la télédétection, dans un dispositif présentant un nombre de variables supérieur au nombre d'individus et des variables corrélées entre elles, comme c'est le cas pour les IV calculés avec les mêmes longueurs d'onde (Li et al., 2014 ; Makowski et al., 2021). Ce modèle serait également moins sujet au surajustement que d'autres modèles présentés précédemment (Yao et al., 2015). Partant de ce constat, le **chapitre 3** a porté sur une nouvelle sélection des variables d'entrée des modèles PLS dans le but d'obtenir un modèle plus opérationnel. Une seconde piste explorée a été la combinaison de mesures prises par proxi- et télédétection.

Pour rappel, dans le **chapitre 2**, les modèles non-paramétriques avaient été construits avec différentes combinaisons de longueurs d'onde en variables d'entrée. Ces combinaisons avaient été calculées à partir des mesures de réflectance dans 15 longueurs d'onde et en utilisant la formulation de 8 IV. Au total, 248 combinaisons ont été calculées. La sélection des variables d'entrée des modèles s'est faite parmi ces 248 combinaisons en se basant sur les valeurs de RMSE obtenues à la suite des régressions linéaires effectuées une à une entre l'INN et ces combinaisons. Les combinaisons minimisant le RMSE ont été sélectionnées d'une part par IV, c'est-à-dire que pour chaque formulation, la combinaison minimisant le RMSE a été choisie. Ceci a donc donné lieu à la création de modèles avec 8 variables d'entrée. Une seconde méthode de sélection a été faite sans tenir compte de la formulation utilisée en se basant sur un seuil afin de sélectionner environ, parmi les 248 combinaisons, les 15% minimisant le RMSE. Au stade Z32, les modèles étaient construits avec 42 variables d'entrée en 2020 et 29 en 2021.

La comparaison entre les modèles PLS construits avec les combinaisons sélectionnées par formulation d'IV et par seuil a mis en évidence qu'en 2020, lorsque le nombre de variables d'entrée est augmenté, le R^2 entraînement obtenu par cross-validation augmente tandis qu'il diminue sur le jeu de validation. En 2021, ces deux R^2 diminuaient lorsque le nombre de variables d'entrée augmentait. Tout l'enjeu est donc d'avoir un modèle présentant un bon compromis entre exactitude et précision des données prédites. Ceci passe par une bonne sélection des variables d'entrée car la qualité du modèle créé est fortement dépendante de ces données d'entrée (Li et al., 2014). Sur le jeu de données de validation, par comparaison entre les modèles PLS avec les combinaisons sélectionnées par formulation d'IV et par seuil de RMSE, les modèles PLS construits avec les meilleures combinaisons par IV permettaient, en 2020 et 2021, d'obtenir le meilleur R^2 validation (0.82 en 2020 et 0.72 en 2021, tableau 2). Cela met en évidence qu'un nombre de variables d'entrée réduit (passant de 42 à 8 en 2020 et de 29 à 8 en 2021) semble diminuer l'erreur de prédiction. De plus, en pratique, il serait plus aisé d'avoir un modèle simple afin de faciliter son utilisation. Toutefois, même si la sélection d'un nombre limité de variables d'entrées semble pertinente dans notre cas, la méthode de sélection par formulation n'est pas la plus adaptée étant donné que certaines formulations ne présentent pas d'intérêt pour prédire l'INN

(**chapitre 2**). Le **chapitre 3** s'est donc intéressé à la sélection des combinaisons minimisant le RMSE avec un nombre de combinaisons sélectionné fixé de façon à créer un modèle ne comptant pas plus de six longueurs d'onde. Ce choix s'explique pour des raisons opérationnelles car la caméra utilisée dispose de six objectifs pouvant prendre des mesures simultanément. Cela facilitera d'une part l'utilisation de la caméra Kernel car la prise d'images dans 15 longueurs d'onde nécessitait 3 survols, entre lesquels la caméra était démontée pour changer les filtres. D'autre part, diminuer le nombre de longueurs d'onde considérées facilitera aussi le déploiement à plus large échelle de cette méthode.

En pratique, deux combinaisons utilisant six longueurs d'onde ont été sélectionnées en 2020 (GNDVI 940-550nm et TCARI/OSAVI 780-632-550-725-850 nm) et cinq combinaisons utilisant quatre longueurs d'onde en 2021 (NG 940-550nm, NG 780-550 nm, NG 940-615 nm, GNDVI 940-550 nm et NG 780-615 nm). En 2021, l'ajout d'une combinaison supplémentaire aurait excédé la limite de six longueurs d'onde. Or, se limiter à 6 longueurs d'onde est l'objectif, sachant que le modèle de caméra utilisé comporte 6 lentilles. La validation de ces modèles met en évidence que cette sélection des variables d'entrée a permis d'augmenter légèrement la qualité de prédiction de l'INN par comparaison aux modèles PLS construits avec les combinaisons sélectionnées par formulation d'IV et par seuil dans le **chapitre 2** (Tableau 2).

Tableau 2 : synthèse des R^2 et R^2 validation obtenus au stade Z32 en 2020 et 2021 pour les combinaisons minimisant le RMSE par année au stade Z32 et les différents modèles PLS construits

Modèle 2020-Z32			
	R^2 entraînement	R^2 validation	Nombre de variables
GNDVI 940-550nm	0.36	0.88	1
PLS avec RMSE seuil	0.40	0.72	42
PLS meilleure combinaison par IV	0.35	0.82	8
PLS 6 longueurs d'onde	0.35	0.83	2
Modèle 2021-Z32			
	R^2 entraînement	R^2 validation	Nombre de variables
NG 940-550nm	0.47	0.72	1
PLS avec RMSE seuil	0.43	0.6	29
PLS meilleure combinaison par IV	0.53	0.72	8
PLS 6 longueurs d'onde	0.46	0.74	5

Tout au long de ces trois années de thèse, en parallèle des survols de drone, un suivi du statut azoté a été réalisé par proxidtection à l'aide d'une pince Dualex. Les outils de proxidtection ont pour avantage d'être faciles d'utilisation et leurs mesures précises, notamment car ils sont beaucoup moins impactés par les conditions de mesure que les mesures prises par télédtection (rayonnement ambiant, effet sol, etc.) (Gabriel et al., 2017 ; Padilla et al., 2018). Le Dualex, en venant pincer la dernière feuille, permet d'estimer le contenu en chlorophylles et flavonols de la feuille à partir de mesures de transmittance et de fluorescence (Cerovic et al., 2012 ; Muñoz-Huerta et al., 2013). Le ratio entre le contenu en chlorophylles et en flavonols permet d'estimer le Nitrogen Balance Index (NBI), un indicateur du statut azoté. La prise en compte de ces 2 types de pigments, qui présentent des corrélations opposées à la concentration en N, est particulièrement intéressante car elle permettrait d'être plus sensible aux changements de statut azoté qu'une estimation basée sur un seul composé (Cartelat et al., 2005). Le **chapitre 1** présente les corrélations obtenues entre le NBI et l'INN en 2019 et 2020 et met en évidence le potentiel du Dualex pour suivre l'INN. Cette capacité de prédiction de l'INN par la mesure du NBI est particulièrement intéressante au début de l'élongation où le R^2

atteignait 0.74 au stade Z32 en 2020. De plus, la relation entre ces 2 indices est stable pour les différents sites, années et variétés suivies. Ainsi, même si la mesure au Dualex est faite sur la dernière feuille, elle semble représentative du statut azoté de la plante entière. Les résultats présentés dans le **chapitre 3** confirment ce potentiel du Dualex. En effet, en combinant les mesures réalisées durant les 3 années au stade Z32, la corrélation entre NBI et INN est élevée ($R^2=0.78$). Ce résultat met en évidence une bonne prédiction des niveaux de l'INN quel que soient les conditions de mesures (années et variétés différentes). Cette corrélation à l'INN est équivalente voire meilleure que les R^2 rapportés dans la littérature pour la culture de blé : $R^2=0.79$ pour Jiang et al. (2021) ; $R^2=0.51$ pour Quemada et al. (2019) ; $R^2=0.56$ pour Cartelat et al. (2005). Ainsi, il est possible d'affirmer que sur blé tendre, le Dualex permet des estimations précises et répétables de l'INN par la mesure du NBI.

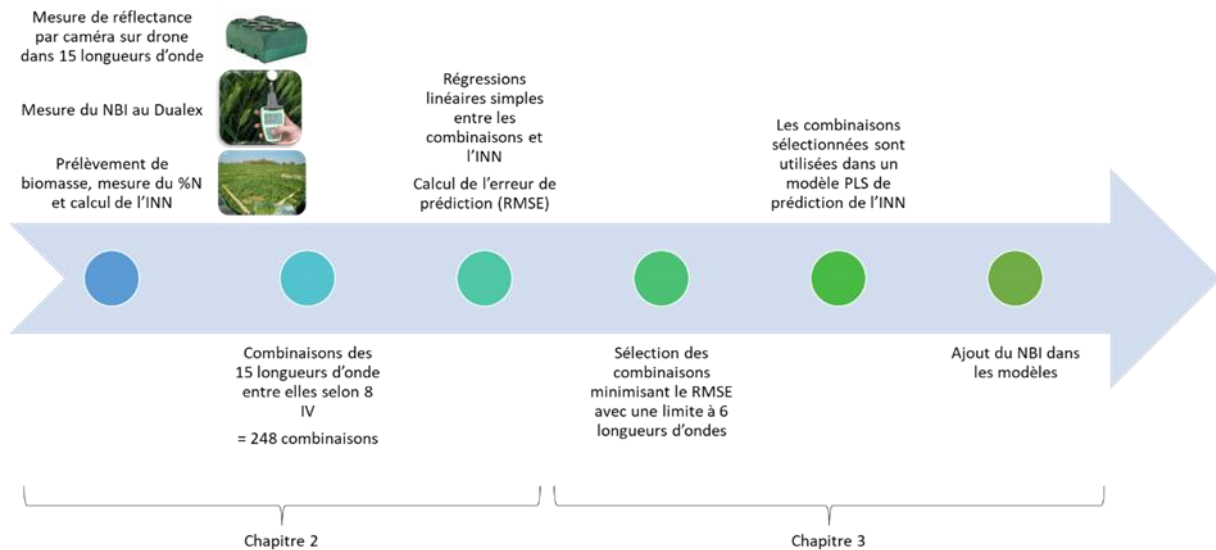


Figure 3 : méthodologie suivie pour construire les modèles PLS avec limite à 6 longueurs d'onde et intégrant le NBI mesuré au Dualex (IV: indice de végétation, INN: indice de nutrition azotée, NBI : Nitrogen balance index mesuré au Dualex)

Pour améliorer le suivi de l'INN, une perspective explorée a donc été de combiner les mesures prises par proxi- et télédétection (figure 3). En effet, le but poursuivi était de cumuler les avantages de la prise de mesure à deux échelles différentes, à savoir la précision de mesures permise par la proxidétéction et la prise en compte de la variabilité spatiale considérée par les mesures faites par imagerie sur drone (télédétection). La capacité de prédiction de l'INN des modèles PLS opérationnels, construits avec les combinaisons minimisant le RMSE avec une limite à 6 longueurs d'onde, a donc été testée au stade Z32 en intégrant le NBI dans le modèle. Les résultats présentés dans le **chapitre 3** mettent en évidence que l'ajout du NBI a permis d'améliorer la capacité de prédiction du modèle en 2020. En effet, le modèle construit avec le GNDVI 940-550nm, le TCARI/OSAVI 780-632-550-725-850 nm et le NBI a permis d'obtenir un $R^2_{\text{entraînement}}=0.72$ par cross-validation et un $R^2_{\text{validation}}=0.97$. En 2021, le modèle construit avec NG 940-550nm, NG 780-550 nm, NG 940-615 nm, GNDVI 940-550 nm, NG 780-615 nm et le NBI a permis d'atteindre des $R^2_{\text{entraînement}}=0.57$ par cross-validation et un $R^2_{\text{validation}}=0.72$ sur le jeu de données de validation. Ainsi, combiner le modèle à six longueurs d'onde et le NBI a permis d'augmenter la qualité de prédiction, excepté en 2021, où par rapport au modèle sans NBI, les performances n'ont pas été améliorées sur le jeu de données de validation. Cependant la validation de ces 2 modèles sur un jeu de données indépendant met en évidence que combiner proxi- et télédétection permet d'améliorer significativement à la fois la qualité de prédiction et la cohérence des valeurs produites. Le modèle PLS 2020 à six longueurs d'onde avec NBI validé sur le jeu de données de 2021 a permis d'obtenir un $R^2=0.59$ (0.45 sans NBI), et le modèle de 2021 validé sur le jeu de données de 2020 un $R^2=0.72$ (0.37 sans NBI).

Ainsi, parmi les modèles PLS construits au stade Z32, les étapes de validation et de test sur un jeu de données indépendant mettent en évidence que les modèles à 6 longueurs d'onde permettent d'obtenir les meilleures prédictions. Dans un second temps, l'ajout du NBI a encore permis d'améliorer le R^2 et la cohérence des valeurs d'INN prédites sur un jeu de données indépendant. Cela met en évidence le potentiel du NBI pour ajuster les valeurs d'INN prédites à partir de mesures faites par télédétection.

2.2. Perspectives d'application à court terme

Les résultats obtenus en combinant les mesures prises par proxi- et télédétection offrent des perspectives intéressantes. Dans un premier temps, à l'image de 2020 et 2021, il paraît important de reconduire le suivi dans une parcelle d'essai présentant un gradient de fertilisation. En effet, d'après la littérature, plus le jeu de données est étoffé (années, sites, variétés et stades différents), plus le modèle entraîné sera robuste et la qualité de prédiction améliorée (Li et al., 2014). Dans notre cas, avec seulement 2 années contrastées, combiner les mesures de 2020 et 2021, n'a pas permis d'améliorer la qualité de prédiction du modèle par rapport aux résultats de 2020 et 2021 considérés indépendamment, ce qui justifie la pertinence d'intégrer une 3^{ème} année dans le suivi. Cela permettrait d'alimenter et d'affiner les modèles créés.

Dans un second temps, dans le but d'élargir le champ d'application de ces modèles, les modèles PLS combinant des mesures par proxi- et télédétection déjà créés en 2020 et 2021 à partir de mesures faites dans des parcelles d'essais, mériteraient d'être testés en parcelle agriculteur. C'est-à-dire dans une parcelle conduite comme le ferai traditionnellement un agriculteur, contrairement aux essais en micro-parcelles. Une prochaine étape sera donc de développer une méthodologie de suivi de l'INN dans une parcelle agriculteur sur la base de ces modèles opérationnels créés en 2020 et 2021 (**chapitre 3**). Les verrous à lever seraient :

- la définition de zones homogènes dans la parcelle
- le maillage de mesures à faire au Dualex en complément des mesures prises par télédétection
- le paramétrage de la méthode.

Un protocole en parcelle agriculteur est proposé et schématisé en figure 4. L'idée est de travailler au sein d'une parcelle agriculteur présentant une bande non fertilisée et une bande sur-fertilisée (dose bilan plus 80 kg.ha⁻¹). Cette parcelle sera survolée au stade Z31 en utilisant la caméra Kernel embarquée sur drone et en mesurant la réflectance du couvert dans les longueurs d'onde identifiées (940nm, 850nm, 780nm, 725nm, 632nm, 615nm et 550nm). A partir de ces mesures, les modèles PLS à 6 longueurs d'onde de 2020 et 2021 pourront être utilisés pour estimer l'INN. Ce premier survol de la parcelle aura pour but de définir des zones homogènes par comparaison aux bandes non fertilisées et sur-fertilisées. Une fois les zones homogènes définies, un second survol au stade Z32 sera effectué et en parallèle, dans les zones homogènes, des prélèvements de biomasses seront réalisés pour mesurer le contenu en N et la biomasse sèche afin de calculer l'INN. 30 mesures au Dualex seront effectuées dans chaque zone homogène, ce chiffre correspondant aux recommandations lorsque le Dualex est utilisé pour piloter le dernier apport. Les mesures au Dualex étant géolocalisées, elles pourront ensuite être intégrées pour améliorer la qualité de suivi de l'INN. La prédiction des modèles retenus en 2020 et 2021 sera ainsi évaluée avec et sans NBI afin de conclure sur la pertinence de la méthode pour suivre le statut azoté. Les mesures prises par télédétection permettront de définir des zones homogènes dans la parcelle tandis que les mesures prises au Dualex devront améliorer la précision des valeurs d'INN prédites. Ce protocole reste une piste d'exploration qui nécessite d'être complétée par un travail sur les INN seuils permettant d'identifier des carences en N (différents des trajectoires d'INN cibles pour piloter la fertilisation). En effet, un modèle plus robuste permettrait de définir un INN seuil qui pourrait servir de base pour définir les zones homogènes et ainsi s'affranchir

des bandes non-fertilisées et sur-fertilisées. Ainsi cette partie propose une application directe dans la continuité des travaux de recherche entamés dans ce travail sur des parcelles d'essais. Des perspectives plus larges feront l'objet d'une discussion dans la partie suivante.




Figure 4 : schéma représentant la méthodologie d'application des modèles PLS avec limite à 6 longueurs d'onde et intégrant le NBI transposé à une parcelle agricole

Pour conclure cette partie, combiner les mesures par proxi- et télédétection présente des perspectives intéressantes pour suivre le statut azoté du blé en cours de campagne en vue d'un pilotage dynamique. Des résultats concluants ont été obtenus au stade Z32. Les mesures par proxidtection améliorant les capacités de prédiction et l'exactitude des données prédites tandis que la télédétection permettrait de prendre en compte les variations spatiales du statut azoté (**chapitre 3**). Ainsi, malgré les limites de la télédétection pour suivre l'INN, il est possible d'évaluer efficacement le statut azoté du blé de façon non destructive en combinant les mesures prises par télédétection à des mesures prises par proxidtection. Ceci améliore significativement la qualité de prédiction des modèles.

De plus, limiter les modèles à 6 longueurs d'onde a à la fois permis d'obtenir un modèle plus opérationnel et d'atteindre de bonnes performances sur le jeu de données de validation, par rapport aux autres modèles testés. Cela présente des perspectives intéressantes car les modèles créés sont souvent complexes et majoritairement basés sur des mesures faites par proxidtection, limitant leur application hors du cadre de la recherche.

Par la suite, ces résultats sur le potentiel de combiner proxi- et télédétection mériteraient d'une part d'intégrer une 3^{ème} année d'expérimentation afin d'alimenter et d'affiner les modèles. D'autre part les modèles créés devront être évalués en parcelle agricole pour confirmer l'intérêt de ces modèles et définir une méthodologie d'application (maillage de mesures au Dualex, définition de zones homogènes).

3. Quel compromis avoir entre les méthodes de pilotage actuelles et les perspectives offertes par la combinaison des mesures prises par proxi- et télédétection pour suivre le statut azoté ?

3.1. Constats sur les performances des OAD

En France, de nombreux outils d'aide à la décision (OAD) sont disponibles pour les agriculteurs afin d'adapter, à la hausse ou à la baisse, la dose totale d'N apportée en cours de campagne, et ce en particulier sur la culture de blé tendre d'hiver. Ces outils se basent sur une estimation ou une mesure du statut azoté de la culture ou de l'N minéral disponible dans le sol. Pour la plupart, ils sont construits de façon à adapter la dose totale d'N calculée en amont de la campagne avec la méthode du bilan (Comifer, 2013). Face à la diversité des outils disponibles sur le marché et à la multiplicité de conseils fournis, le **chapitre 5** a porté sur l'évaluation des performances agronomiques et environnementales de quatre de ces outils, par comparaison à la dose bilan et à un témoin non fertilisé. L'étude s'est faite sur 2 sites d'essais, à l'échelle d'une succession culturale orge – blé – colza – blé, de 2017 à 2020.

Les résultats obtenus mettent en évidence que quel que soit le type d'outil, basé sur des mesures en cours de campagne ou sur des modèles, les doses conseillées étaient en grande majorité supérieures à la dose bilan. Pour une même situation (année, culture, parcelle), les écarts à la dose bilan pouvaient atteindre jusqu'à 80 kg N.ha⁻¹ de déplafonnement. A la récolte, ces déplafonnements ne se sont pas traduits par une amélioration significative du rendement ou de la qualité dans les conditions des années étudiées. En effet, l'étude du coefficient apparent d'utilisation de l'N (CAU, équivalent à l'ANR) met en évidence, pour la culture de blé, que les doses d'apport élevées conseillées par les OAD ont été mal valorisées. Cela s'est particulièrement observé en 2018, année sèche par rapport aux normales de saison, mettant en évidence la mauvaise prise en compte des conditions environnementales optimales de valorisation des apports dans les conseils. A la récolte, cela s'est alors traduit par un contenu en N minéral du sol supérieur à la valeur attendue dans les références nationales (INRAE, 2012 in Comifer, 2013). La relation entre la sur-fertilisation (Beaudoin et al., 2005), et l'excès d'N à la récolte met en évidence qu'une sur-fertilisation de 50 kg N.ha⁻¹ entraîne un excès significatif d'N dans le sol à la récolte. Toutefois, il est intéressant de pointer ici que la méthode du bilan présente rarement une sur-fertilisation supérieure à ces 50 kg N.ha⁻¹. Ces résultats questionnent donc sur la pertinence des OAD actuels qui devraient pourtant, grâce à une meilleure adaptation au contexte annuel, éviter ces situations de sur-fertilisation (Diacono et al., 2013). Ce constat, ainsi que l'absence d'amélioration des performances à la récolte dans le contexte étudié, ne permettent pas de conclure sur la pertinence de l'utilisation de la méthode du bilan couplée à des capteurs ou des modèles, telle que proposée aux agriculteurs aujourd'hui.

3.2. Perspectives ouvertes par le pilotage dynamique

3.2.1. Nécessité d'une meilleure prise en compte des conditions de valorisations des apports

Les résultats obtenus dans le **chapitre 5** amènent à se questionner sur les seuils utilisés par les OAD pour diagnostiquer un déficit azoté, sur leur prise en compte de l'évolution du statut azoté de la plante ou du contenu en N du sol entre le diagnostic et le conseil ainsi que sur la considération des conditions du milieu au moment de l'apport ; tous ces éléments pouvant expliquer l'absence de différences significatives observées par rapport à la méthode du bilan.

Ces observations sur les limites du pilotage actuel s'inscrivent dans un contexte de changement de paradigme de la fertilisation azotée, à la suite du travail de Ravier et al. (2016), proposant de s'affranchir de l'objectif de rendement pour piloter les apports sur la base d'une trajectoire d'INN optimale (Ravier et al., 2018 ; Ravier et al. 2021). Cette trajectoire optimale prend en compte les carences en N tolérables, en début de cycle, sans impact sur le rendement (Ravier et al., 2016 ; Jeuffroy et Bouchard., 1999). La courbe définie vise des INN de 0.4, 0.7, 0.7, 0.8 aux stades Z30, Z32, Z39 et Z60 respectivement (Ravier et al., 2017a).

À la suite de cela, 2 méthodes basées sur cette trajectoire ont été proposées et testées. La méthode Appi-N de l'INRAe se base sur un suivi de l'INN à la parcelle et sur un abaque construit à partir du modèle Azodyn (Jeuffroy et Recous, 1999), qui propose une dose d'apport en fonction du stade de mesure et de l'INN calculé. L'INN est calculé à partir de mesures faites à la pince N-tester (Yara, Oslo, Norvège) en parcelle agriculteur et sur une placette sur-fertilisée (+ 50 kgN.ha⁻¹ à chaque apport). Le N-tester est un capteur optique foliaire, estimant la teneur en chlorophylles à partir du ratio de lumière transmise dans les longueurs d'onde 650 et 940nm (Arranguren et al., 2020). La méthode CHN, développée par Arvalis, est quant à elle basée sur un modèle agronomique (Soenen et al., 2017). Ce modèle propose de déterminer l'évolution de l'INN en cours de croissance de la culture en se basant sur différents paramètres définis en entrée (précédent cultural, date et densité de semis, type de sol, travail du sol, matière organique apportée, etc.) à un pas de temps journalier. La prise en compte de la météo historique permet d'identifier des périodes pour lesquelles les conditions sont favorables à un apport d'N. Ces 2 méthodes permettraient donc une meilleure prise en compte des conditions d'apport, d'une part grâce aux abaques définis en amont sur base de simulations (modèle Azodyn) dans la méthode Appi-N et d'autre part grâce à l'utilisation d'un modèle en cours de croissance pour la méthode CHN. Les résultats obtenus dans le **chapitre 5**, mettant en évidence le manque de prise en compte des conditions de valorisation des apports dans les conseils, confirment qu'une approche dynamique basée sur un ajustement des doses d'apport en saison serait intéressante.

3.2.2. Importance de considérer la mise en place des composantes de rendement

Dans ce contexte, en s'affranchissant de l'objectif de rendement et en se basant sur la plante comme indicateur de son statut azoté, une meilleure connaissance de la mise en place des composantes de rendement et de la valorisation des apports en fonction des pratiques de fertilisation présente un intérêt pour construire une démarche de pilotage dynamique.

Le **chapitre 4** s'est intéressé à la mise en place des composantes de rendement et à la valorisation des apports en fonction des stratégies de pilotage de la fertilisation. 13 stratégies ont été évaluées en 2020 et 20 en 2021. Parmi les composantes étudiées, le nombre d'épis par m² est la composante la plus déterminante du rendement en 2020 et parmi les plus déterminantes en 2021. Cela est cohérent avec les résultats de Slafer et al. (2014), Orloff et al. (2012), Ferrante et al. (2017), pour qui le nombre de grains et le nombre d'épis par unité de surface sont fortement corrélés au rendement. Cette composante est également la plus fortement impactée par la fertilisation ; la relation obtenue entre la fertilisation et le nombre d'épis par m² étant significative les deux années étudiées (p-value=1e-04 en 2020 et p-value=4e-04 en 2021). L'étude de l'effet du cumul de dose apporté par stade d'apport met en évidence un effet significatif de la fertilisation dès le stade tallage pour les 2 années étudiées. Cet effet est ensuite significatif jusqu'au dernier apport, à dernière feuille étalée en 2020 (Z39) et épiaison (Z59) en 2021. Dans le contexte des 2 essais étudiés, la fertilisation semble jouer un rôle majeur sur le maintien des talles fertiles, expliquant les corrélations entre la fertilisation, le nombre d'épis par m² et les performances à la récolte.

L'étude de l'impact des stratégies de fertilisation sur le rendement révèle que, parmi les stratégies permettant d'atteindre le meilleur rendement, celles dont la dose totale est équivalente à la dose bilan

mais avec un apport élevé au tallage (80 kg N.ha^{-1}) atteignent les meilleures performances dans les conditions des essais. En effet, à la récolte, ces modalités permettent d'obtenir les meilleurs rendements ou n'obtiennent pas de rendements significativement différents des modalités dont la dose totale d'apport excède la dose bilan. Ces résultats sont contraires à la notion de carences tolérables en début de cycle proposée par Jeuffroy et Bouchard (1999) et reprise dans le cadre de la méthode de pilotage dynamique proposée par Ravier et al. (2017a). En effet les résultats du **chapitre 4** mettent en évidence qu'en 2021, les modalités dont l'INN était inférieur à 0.7 au stade Z32 ont eu les rendements les plus faibles à la récolte. Cela démontre que des variantes régionales des trajectoires optimales seraient nécessaires. Toutefois, même si cette tendance a été observée sur les 2 années d'essais, il est important de garder à l'esprit que cette étude a été conduite sur 2 parcelles pour 2 années contrastées en termes de conditions météorologiques, à quoi s'ajoute des conditions de semis différentes. En effet, le semis de 2020 a été réalisé en semis direct après colza, tandis qu'en 2021 il s'agissait de semis direct après betteraves en conditions humides. Les conditions de 2021 n'ont pas été propices à une levée régulière et à un bon enracinement ce qui peut expliquer les besoins d'azote importants en surface et les différences obtenues entre les 2 années (Labreuche et al., 2013). Ainsi, des essais dans d'autres conditions pédoclimatiques seront nécessaires pour confirmer cette tendance.

Un lien peut également être fait avec les résultats obtenus en **chapitre 5**. En effet, vue l'importance des apports en début de cycle et début montaison sur la mise en place et le maintien du nombre d'épis.m², il semblerait que le pilotage par les OAD intervient trop tard en saison. Cela paraît également pertinent étant donné qu'il est avéré que la valorisation des premiers apports est moins bonne que pour des apports plus tardifs (Sieling et Kage, 2021), ce qui a été confirmé en 2020 et 2021 et présenté dans le **chapitre 4**. Ainsi, piloter plus tôt les apports en cours de croissance permettrait d'avoir une meilleure prise en compte de la mise en place des composantes de rendement mais également de mieux prendre en considération le statut azoté et d'améliorer la valorisation des apports qui est moins bonne que pour des apports tardifs. Ce constat met également en évidence qu'il serait intéressant d'évaluer la capacité de prédiction des modèles combinant mesures par proxi- et télédétection, créés à Z32 (**chapitre 3**), lorsque qu'ils sont appliqués dès le tallage afin de permettre un pilotage précoce.

3.2.3. Potentiel de l'application d'un suivi multi-capteur combinant proxi- et télédétection

Combiner les mesures par proxi- et télédétection présente des perspectives intéressantes pour être appliqué dans le cadre d'un pilotage dynamique de la fertilisation. Ravier et al. (2018), mettent en avant qu'un suivi régulier de l'INN permet aux agriculteurs de mieux comprendre le conseil et de se rassurer en effectuant eux-mêmes une mesure. Combiner mesures par proxi- et télédétection va donc dans ce sens. Toutefois, dans la méthode Appi-N proposée par l'INRAe, le suivi est uniquement basé sur une mesure ponctuelle de l'INN à la pince N-tester (Ravier et al., 2017b). De plus les mesures prises par le N-tester n'étant basée que sur une mesure de la teneur en chlorophylles par transmittance, cet outil serait moins performant que le Dualex prenant en compte le contenu en chlorophylles et en flavonols. En effet, la relation entre les mesures du N-tester et l'INN sont controversées. Naud et al. (2009) ont mis en évidence une relation linéaire significative entre les mesures au N-tester et la concentration en N du couvert (%N) au stade 2 nœuds ($R^2=0.63$), tandis qu'Arranguren et al. (2020), dans leur comparaison du RapidScan CS-45 (Holland Scientific, Lincoln, USA) et de la pince N-tester pour estimer l'INN du blé, n'obtiennent pas de relations significatives entre les mesures normalisées obtenues au N-tester (ratio valeur mesurées et valeur mesurée sur placette surfertilisée) et l'INN. Dans cette dernière étude, des corrélations significatives avaient cependant été établies entre les valeurs normalisées mesurées au N-tester et le rendement ($R^2=0.56$ au stade Z65, Arranguren et al., 2020).

Ainsi le Dualex, qui permet une estimation stable et précise de l'INN ($R^2=0.78$), en combinaison avec des mesures prises par télédétection permettrait d'ajuster la prédiction de l'INN tandis que les mesures prises par télédétection permettent de prendre en compte les variations spatiales du statut azoté. Cela présente un intérêt particulier étant donné que selon la méthode proposée par Ravier et al. (2021), un abaque de dose d'apport est basé sur des INN seuil en fonction des stades. Il est donc important d'estimer une valeur la plus exacte possible d'INN et non pas une valeur corrélée à l'INN.

Dans ce contexte, comme évoqué précédemment, une application intéressante est offerte par les modèles PLS combinant IV et mesures prises au Dualex. Le fait d'avoir un modèle performant ne prenant en compte que 6 longueurs d'onde permettrait également de ne plus être dépendant de la caméra Kernel. En effet, celle-ci montée sur un drone est tout à fait adaptée à la recherche en permettant une certaine souplesse d'utilisation concernant le choix des dates de vols et des longueurs d'onde mesurées, que ne permettent pas les mesures prises par satellite par exemple. Toutefois, dans la pratique, son application est limitée notamment à proximité d'agglomérations (Alvarez-Vanhard et al., 2021). En effet, plusieurs contraintes sont à considérer et peuvent compliquer la mise en œuvre des mesures à proximité de zones urbaines. Il s'agit par exemple de l'interdiction de survol de certaines zones, de la nécessité de s'éloigner des lignes à haute tension (à cause du champ magnétique généré qui perturbe le compas), de vérifier l'absence d'obstacles à proximité qui peuvent perturber le signal GPS rendant le pilotage fastidieux, etc. C'est à cause de ces difficultés que l'acquisition des données en parcelle agriculteur, prévue en 2021, n'a pas pu être menée à terme. Ainsi, afin d'aboutir à un modèle plus opérationnel, il serait également intéressant d'évaluer si la combinaison de mesures prises par satellite en combinaison avec les mesures prises par Dualex permet également d'obtenir une estimation de qualité de l'INN. Par exemple, par rapport aux bandes identifiées dans cette étude pour les modèles PLS avec une limite à six longueurs d'onde (i.e., 940nm, 850nm, 780nm, 725nm, 632nm, 615nm et 550nm), les longueurs d'onde mesurées par le capteur MSI du satellite sentinel-2 les plus proches seraient : 945nm (± 20), 864nm (± 20), 782.5nm (± 20), 703.9nm (± 20), 560nm (± 20) (ESA, 2021). Comme évoqué précédemment, il apparaît à nouveau ici que peu de capteurs effectuent des mesures dans la portion orange-début du rouge du spectre. Pour faire des comparaisons plus fines entre les résultats obtenus avec la caméra Kernel et/ou appliquer la démarche à des images satellites, les caméras hyperspectrales embarquées sur satellite présentent plus d'opportunités. C'est le cas par exemple du spectrophotomètre HISUI (Ministère japonais de l'économie, du commerce et de l'industrie) mis en place sur la station spatiale internationale et prenant des mesures entre 400 et 2500nm, tous les 10-12nm (Matsunaga et al., 2017 in Berger et al., 2020).

Coupler imagerie satellite et mesures au Dualex permettrait une diffusion de cette méthodologie à plus grande échelle. Cela rejoint également la proposition de pilotage dynamique proposé par Arvalis en couplant leur modèle CHN avec des mesures issues d'images prises par caméra embarquée sur satellite (Soenen et al., 2017). Cependant, il est avéré que l'acquisition d'images satellite est peu flexible comparée au drone, celle-ci étant à la fois dépendante de la révolution du satellite mais également de la couverture nuageuse (Späti et al., 2021 ; Manfreda et al., 2018 ; Alvarez-Vanhard et al., 2021). En pratique il est parfois difficile de synchroniser la date d'acquisition des images au stade ciblé. Ainsi, il est d'autant plus pertinent de coupler l'utilisation des images satellites à un outil portable et facile d'utilisation comme le Dualex, celui-ci permettrait de pallier au manque de flexibilité de la prise de mesure du satellite en permettant un ajustement au plus proche des dates cibles à partir de mesures du NBI. Une plus-value serait également apportée par l'utilisation du Dualex pour améliorer la précision des valeurs d'INN estimés.

Pour conclure, l'étude de 4 méthodes de pilotage actuelles basées sur l'utilisation d'OAD en cours de campagne, n'a pas permis de mettre en évidence dans nos essais une plus-value à l'utilisation de ces OAD par rapport à la méthode du bilan (**chapitre 5**). L'étude de la mise en place des composantes de rendement montre que la composante majeure, le nombre d'épis.m², est influencée dès le tallage par la fertilisation (**chapitre 4**). Ceci confirme l'intérêt de piloter les apports plus tôt en saison, comme proposé par Ravier et al. (2016, 2017) et expérimenté par l'INRAe et Arvalis. Dans ce contexte, les résultats obtenus avec les modèles combinant les mesures prises par proxi- et télédétection présentent des perspectives intéressantes, et leur capacité de prédiction avant Z32 mériterait donc d'être testée. Cela permettrait d'une part d'adapter les doses d'apports aux besoins de façon plus précoce que ce qui est réalisé actuellement et d'autre part de mieux considérer la mise en place et le maintien des composantes de rendement. Toutefois, des adaptations de la courbe seuil d'INN devraient être proposées afin de permettre une meilleure prise en compte des conditions dans lesquelles une carence à tallage serait préjudiciable. Pour cela l'étude de la valorisation des apports devrait être poursuivie afin de prendre en compte les bénéfices mais aussi les risques environnementaux pouvant être associés à des apports précoces en saison.

Comme évoqué précédemment, une perspective intéressante est offerte par les modèles PLS combinant IV et mesures prises au Dualex. Les mesures par proxidétection améliorant les capacités de prédiction du statut azoté de la culture et l'exactitude des données prédites tandis que la télédétection permettrait de prendre en compte les variations spatiales de ce statut azoté dans la parcelle (**chapitre 3**). Celle-ci pourrait être adoptée dans une démarche de pilotage dynamique pour permettre un diagnostic du statut azoté de la culture en cours de croissance.

Aussi, afin d'aboutir à un modèle plus opérationnel, il serait également intéressant d'évaluer si la combinaison de mesures prises par satellite avec celles prises par Dualex permettrait d'obtenir une estimation de qualité de l'INN. Cela permettrait une diffusion de cette méthodologie à plus large échelle tout en gardant la possibilité de spatialiser les informations collectées.

Conclusion

Pour atteindre l'objectif important d'amélioration de l'efficacité de la valorisation des apports de fertilisants minéraux azotés par les cultures, une meilleure considération de la variabilité spatiale et temporelle de leurs besoins en azote (N) est essentielle. Celle-ci permettrait d'ajuster plus finement les apports aux besoins de la culture et ainsi d'améliorer leur valorisation. Pour parvenir à cela, la connaissance du statut azoté du couvert végétal en cours de croissance est primordiale. L'objectif de cette thèse était de développer une méthode de suivi et d'évaluation non-destructive de ce statut azoté, via le suivi de l'indice de nutrition azotée (INN) du blé tendre en cours de campagne, dans le but d'intégrer par la suite ces connaissances dans une démarche de pilotage dynamique de la fertilisation azotée.

Nos essais menés de 2019 à 2021 nous ont permis de mettre en évidence que, même en utilisant une caméra multispectrale mesurant la réflectance dans 15 longueurs d'onde différentes, la capacité des indices de végétation (IV) à suivre le statut azoté du blé reste moyenne. Il a en effet été difficile, parmi toutes les combinaisons testées, d'obtenir un IV discriminant qui permette de prédire efficacement l'INN. Parmi les combinaisons minimisant l'erreur de prédiction, une tendance a toutefois pu être identifiée au stade 2 nœuds (Z32) avec la mise en évidence de l'intérêt de combiner la réflectance dans le vert (550nm) et le proche infrarouge (NIR, 940nm). A gonflement, la combinaison de mesures prises dans le début du début du NIR (780-808nm) avec la réflectance mesurée dans l'orange-début du rouge (590-615nm) présentait le plus d'intérêt. Toutefois, les coefficients de détermination (R^2) obtenus restent moyens et atteignant au maximum 0.58 (NG 550-790nm, 2019), 0.47 (NG 550-940nm, 2020) et 0.56 (GNDVI 615-780nm), respectivement aux stades épis 1cm (Z30), Z32 et dernière feuille étalée (Z39), cela nous a conduit à étudier le potentiel des modèles de prédiction non-paramétriques pour atteindre notre objectif. En effet, contrairement aux modèles paramétriques qui reposent sur des relations connues entre des variables, les modèles non-paramétriques se basent sur le jeu de données pour construire le modèle le plus adapté permettant d'établir des liens entre un ensemble de variables explicatives, dans le but de prédire au mieux une variable réponse d'intérêt ; le statut azoté (INN) dans notre cas.

Quatre modèles de régression non paramétriques ont été construits sur base des combinaisons de mesures de réflectance à notre disposition : la régression pénalisée de Ridge, la régression par les moindres carrés partiels (PLS), la régression sur les composantes principales (PCR) et les forêts aléatoires (RF). Pour les deux années considérées, la validation et le test de ces modèles ont mis en évidence que les modèles étaient plus stables et performants au stade Z32 qu'aux stades Z39 et Z45. Cela présente des perspectives intéressantes en vue de piloter la fertilisation, les besoins en N de la culture augmentant courant montaison. Les différentes étapes de validation et de test sur un jeu de données indépendant nous ont amenés à sélectionner les modèles PLS comme les plus adaptés à notre objectif.

Cependant, ces modèles ne permettant pas d'améliorer la qualité de prédiction de l'INN de façon notable par rapport aux meilleures combinaisons d'IV étudiées individuellement, nous avons choisi de combiner des mesures faites par proxidtection aux modèles PLS utilisant les combinaisons issues de mesures par télédétection faites par drone. Ceci nous a permis d'améliorer considérablement les résultats de nos prédictions du statut azoté (INN). Nous avons en effet pu montrer que notre capteur de proxidtection (Dualix) utilisé seul permet une estimation stable et précise de l'INN via la mesure du NBI ($R^2=0.78$ au stade Z32), sans cependant pouvoir prendre facilement en compte la variabilité

spatiale des besoins en N. Couplée au modèle PLS construit à partir de combinaisons d'IV utilisant 6 longueurs d'onde, la mesure du NBI a permis d'augmenter le R^2 et de diminuer l'erreur de prédiction par rapport aux modèles n'utilisant pas ces données de proxidétection. Au stade Z32, les R^2 de ces modèles atteignaient 0.59 pour le modèle de 2020 testé sur le jeu de données de 2021 et 0.72 pour le modèle de 2021 testé sur le jeu de données de 2020.

Pour atteindre notre objectif principal d'estimation non destructive du statut azoté du blé tendre en vue de la mise en place d'une méthode de pilotage dynamique de la fertilisation azotée, combiner les mesures par proxi- et télédétection présente donc des perspectives particulièrement intéressantes ; les mesures par proxidétection améliorant les capacités de prédiction du statut azoté de la plante et l'exactitude des données prédites tandis que la télédétection permettrait de prendre en compte les variations spatiales de ce statut azoté dans la parcelle. En parallèle de premiers essais de mise en pratique de ces modèles en parcelle agriculteur, il paraît important de reconduire le suivi, tel que cela a été fait en 2020 et 2021, dans une parcelle d'essai présentant un gradient de fertilisation afin d'étoffer notre jeu de données et rendre notre modèle plus robuste.

Dans l'objectif de proposer une nouvelle méthode de pilotage de la fertilisation qui tienne compte des avantages et inconvénients de l'existant, un second volet de cette thèse a porté sur le suivi des performances agronomiques et environnementales de quatre outils d'aide à la décision (OAD) proposés actuellement aux agriculteurs pour piloter la fertilisation. Cette étude a été conduite sur 2 sites d'essais, à l'échelle d'une succession culturale orge – blé – colza – blé. Les résultats obtenus mettent en évidence que quel que soit le type d'outil, basé sur des mesures en cours de campagne ou sur des modèles, les doses conseillées pour une même situation (année, culture, parcelle) étaient en grande majorité supérieures à la dose bilan. A la récolte, ces déplafonnements ne se sont pas traduits par une amélioration significative du rendement ou de la qualité dans les conditions des années étudiées. L'étude du coefficient apparent d'utilisation de l'N (CAU, équivalent à l'ANR) met en évidence, pour la culture de blé, que les doses d'apport élevées conseillées par les OAD ont été mal valorisées. Cela s'est particulièrement observé en 2018, année sèche par rapport aux normales de saison. Ces résultats n'ont donc pas permis de mettre en évidence dans nos essais une plus-value à l'utilisation de ces OAD par rapport à la méthode du bilan telle que proposée aux agriculteurs aujourd'hui. Ces observations sur les limites du pilotage actuel s'inscrivent dans un contexte de changement de paradigme de la fertilisation azotée, repris dans ce travail, et développé par d'autres auteurs. Ces derniers proposent de s'affranchir de la méthode du bilan pour piloter les apports sur la base de mesures régulières du statut azoté de la culture, mesures qui seraient confrontées à une trajectoire d'INN optimale (Ravier et al., 2018 ; Ravier et al. 2021). Cette approche dynamique permettrait une meilleure considération des conditions annuelles.

L'étude de la mise en place des composantes de rendement sur les parcelles d'essais suivies en 2020 et 2021 permet d'appuyer en partie cette dernière conclusion. En effet, la composante contribuant majoritairement au rendement, le nombre d'épis.m⁻² est influencée dès le tallage par la fertilisation. Dans ce contexte, le pilotage des apports d'azote dès le stade tallage est pertinent pour atteindre l'optimum de cette composante de rendement. Si cela confirme l'intérêt de piloter les apports plus tôt en saison, la tolérance de carences azotées en sortie hiver proposée par certains auteurs est toutefois remise en cause dans nos situations. Dans le cadre des essais suivis, l'étude de différentes stratégies de fertilisation n'a pas permis de mettre en évidence un effet significatif des différentes pratiques de fertilisation sur l'ANR global. Cela souligne d'une part la pertinence de suivre le statut azoté de la culture pour synchroniser les apports et les besoins, mais également la nécessité de poursuivre le travail d'évaluation des risques environnementaux associés à des apports précoces.

En perspective à ce travail, une méthode de fertilisation dynamique, basée sur un diagnostic précoce du statut azoté, serait pertinente et pourrait être proposée sous forme d'un modèle de suivi de l'INN combinant des mesures prises par proxi- et télédétection. Dans ce contexte, notre méthode actuelle de suivi de l'INN du blé au stade Z32, précise et spatialisée, pourrait être adaptée pour ajuster les apports en cours de montaison. En association avec des règles de décision permettant de définir une dose adaptée à l'INN mesuré, une telle méthode permettrait d'ajuster les doses des apports suivant et ainsi améliorer l'efficacité de l'utilisation de l'N.

Références bibliographiques

- Aasen H., Honkavaara E., Lucieer A., Zarco-Tejada P.J., 2018. Quantitative Remote Sensing at Ultra High Resolution with UAV Spectroscopy: A Review of Sensor Technology, Measurement Procedures, and Data Correction Workflows. *Remote Sensing*, 10(7), pp. 1091-1032. doi.org/10.3390/rs10071091.
- Abis S., 2015. Le blé au cœur des enjeux géostratégiques mondiaux. *Hérodote, revue de géographie et de géopolitique*, 156, pp. 125-137.
- Alvarez-Vanhard E., Corpetti T., Houet T., 2021. UAV & satellite synergies for optical remote sensing applications: A literature review. *Science of Remote Sensing*, 3. doi.org/10.1016/j.srs.2021.100019.
- Aranguren M., Castellon A., Aizpurua A., 2020. Crop Sensor Based Non-destructive Estimation of Nitrogen Nutritional Status, Yield, and Grain Protein Content in Wheat. *Agriculture*, 10, pp. 148-170. doi.org/10.3390/agriculture10050148.
- Argento F., Anken T., Abt F., Vogelsanger E., Walter A., Liebisch F., 2020. Site-specific nitrogen management in winter wheat supported by low-altitude remote sensing and soil data. *Precision Agriculture*, 22, pp. 364-386. doi.org/10.1007/s11119-020-09733-3.
- Arregui L., Lasa B., Lafarga A., Irañeta I., Baroja E., Quemada M., 2006. Evaluation of chlorophyll meters as tools for N fertilization in winter wheat under humid Mediterranean conditions. *European Journal of Agronomy*, 24, pp. 140-148. doi.org/10.1016/j.eja.2005.05.005.
- Arvalis. 2014. Fractionner l'azote en trois apports. Disponible en ligne : <https://www.arvalisinfos.fr/fractionner-l-azote-en-trois-apports-@/view-12293-arvarticle.html#:~:text=Afin%20de%20suivre%20au%20plus,noeuds%20et%20le%20stade%20gonflement> **Erreur ! Référence de lien hypertexte non valide.**(consulté le 17/10/2021)
- Arvalis. 2018. Comment s'élabore le rendement des céréales à paille ? Disponible en ligne : <https://www.arvalis-infos.fr/comment-s-elabore-le-rendement--@/view-16191-arvarticle.html> (consulté le 17/10/2021)
- Atzberger C., Berger K., Vuolo F., Darvishzadeh R., Schlerf M., 2011. Why confining to vegetation indices? Exploiting the potential of improved spectral observations using radiative transfer models. In: *SPIE Remote Sensing Europe*, (Prague, Czech Republic). doi.org/10.1117/12.898479.
- Bao Y., Xu K., Min J., Xu J., 2013. Estimating Wheat Shoot Nitrogen Content at Vegetative Stage from In Situ Hyperspectral Measurements. *Crop Science*, 53, pp. 2063-2071. doi.org/10.2135/cropsci2013.01.0012.
- Baret F. et Fourty T. 1997. Radiometric estimates of nitrogen status of leaves and canopies. *Diagnosis of the Nitrogen Status in Crops*, pp. 201-227. doi.org/10.1007/978-3-642-60684-7_12.
- Barnes E.M., Clarke T.R., Richards S.E., Colaizzi P.D., Haberland J., Kostrzewski M., Waller P., Choi C., Riley E., Thompson T., Lascano R.J., Li H., Moran M.S., 2000. Coincident Detection of Crop

- Water Stress, Nitrogen Status and Canopy Density Using Ground-Based Multispectral Data. Proceedings of the Fifth International Conference on Precision Agriculture, ASA, Madison, WI.
- Basso B., Fiorentino C., Cammarano D., 2015. Variable rate nitrogen fertilizer response in wheat using remote sensing Agriculture. Precision Agriculture, 17, pp. 168-182.
- Beaudoin N., Saad J.K., Van Laethem C., Mchet J.M., Maucorps J., Mary B., 2005. Nitrate leaching in intensive agriculture in Northern France: Effect of farming practices, soils and crop rotations. Agriculture, Ecosystems and Environment, 111, pp. 292-310. doi.org/10.1016/j.agee.2005.06.006.
- Ben Abdallah F., Goffart J. P., Philippe W., 2016. Utilisation de la fluorescence chlorophyllienne pour l'évaluation du statut azoté des cultures. Biotechnologie, agronomie, société et environnement, 20(1), pp. 83-93. doi.org/10.25518/1780-4507.12627
- Berger K., Verrelst J., Féret J.B., Wang Z., Woche M., Strathmann M., Danner M., Mauser W., Hank T. 2020. Crop nitrogen monitoring: Recent progress and principal developments in the context of imaging spectroscopy missions. Remote Sensing of Environment, 242. doi.org/10.1016/j.rse.2020.111758.
- Bibi S., Saifullah, Naeem A., Dahlawi S. 2016. Environmental Impacts of Nitrogen Use in Agriculture, Nitrate Leaching and Mitigation Strategies. Soil Science: Agricultural and Environmental Perspectives, pp. 131-157. doi.org/10.1007/978-3-319-34451-5_6.
- Bollas N., Kokinou E., Polychronos V. 2021. Comparison of Sentinel-2 and UAV Multispectral Data for Use in Precision Agriculture: An Application from Northern Greece. Drones, 5, pp. 35-56. doi.org/10.3390/drones5020035.
- Briat J.F., Gojon A., Plassard C., Rouached H., Lemaire G., 2020. Reappraisal of the central role of soil nutrient availability in nutrient management in light of recent advances in plant nutrition at crop and molecular levels. European Journal of Agronomy, 116. doi.org/10.1016/j.eja.2020.126069
- Briat J.F., Lemaire G., 2021. Nourrir les plantes en polluant moins ? Disponible en ligne : <https://www.encyclopedie-environnement.org/vivant/nourrir-plantes-polluant-moins/> (consulté le 30/09/2021)
- Brown B., Westcott M., Christensen N., Pan B., Stark J., 2005. Nitrogen Management for Hard Wheat Protein Enhancement. PNW 578.
- Buschmann C., 2007. Variability and application of the chlorophyll fluorescence emission ratio red/far red of leaves. Photosynthesis Research, 92(2), pp. 261-271. doi.org/10.1007/s11120-007-9187-8.
- Buschmann C., Nagel E., 1993. In vivo spectroscopy and internal optics of leaves as basis for remote sensing of vegetation. International Journal of Remote Sensing, 14, pp. 711-722. doi.org/10.1080/01431169308904370.
- Calderini D.F., Castillo F.M., Arenas-M A., Molero G., Reynolds M.P., Craze M., Bowden S., Milner M.J., Wallington E.J., Dowle A., Gomez L.D., McQueen-Mason S.J., 2021. Overcoming the trade-off between grain weight and number in wheat by the ectopic expression of expansin in developing seeds leads to increased yield potential. New Phytologist, 230, pp. 629-640. doi.org/10.1111/nph.17048.

- Cartelat A., Cerovic Z. G., Goulas Y., Meyer S., Lelarge C., Prioul J. L., 2005. Optically assessed contents of leaf polyphenolics and chlorophyll as indicators of nitrogen deficiency in wheat (*Triticum aestivum* L.). *Field Crops Research*, 91, pp. 35–49. doi.org/10.1016/j.fcr.2004.05.002.
- Caturegli L., Gaetani M., Volterrani M., Magni S., Minelli A., Baldi A., Brandani G., Mancini M., Lenzi A., Orlandini S., Lulli F., De Bertoldi C., D'Ubbini M., Grossi N., 2020. Normalized Difference Vegetation Index versus Dark Green Colour Index to estimate nitrogen status on bermudagrass hybrid and tall fescue. *International Journal of Remote Sensing*, 41:2, pp. 455-470. doi.org/10.1080/01431161.2019.1641762.
- Cellier P., 2019. De la fertilisation des cultures à la cascade de l'azote. *Agronomie, Environnement & Sociétés, Association Française d'Agronomie (Afa)*, 9, pp. 13-17.
- Cerovic Z.G., Masdoumier G., Ben Ghazlen N., Latouche G., 2012. A new optical leaf-clip meter for simultaneous non-destructive assessment of leaf chlorophyll and epidermal flavonoids. *Physiologia Plantarum*, 146, pp. 251–260. doi.org/10.1111/j.1399-3054.2012.01639.x
- Chaire AgroTIC. 2018. Deep learning et agriculture, comprendre le potentiel et les défis à relever. Disponible en ligne : https://www.agrotic.org/wp-content/uploads/2018/12/2018_ChaireAgroTIC_DeepLearning_VD2.pdf (consulté le 11/10/2021)
- Charmet G., Abécassis J., Bonny S., Fardet A., Forget F., Lullien-Pellerin V., 2017. *Agriculture et alimentation durables, Trois enjeux dans la filière céréales*. Editions Quae. ISBN : 978-2-7592 2624-5
- Chen P. 2015. A comparison of two approaches for estimating the wheat nitrogen nutrition index using remote sensing. *Remote sensing*, 7, pp. 4527-4548. doi.org/10.3390/rs70404527.
- CNES. Sentinel-2, des vues de la terre d'une qualité radiométrique sans précédent. Disponible en ligne : <https://sentinel2.cnes.fr/fr> (consulté le 11/10/2021)
- Colaço A.F., Bramley R.G.V., 2018. Do crop sensors promote improved nitrogen management in grain crops? *Field Crops Research*, 218, pp. 126-140. doi.org/10.1016/j.fcr.2018.01.007.
- COMIFER. 2013. Calcul de la fertilisation azotée. Guide méthodologique pour l'établissement des prescriptions locales. Cultures annuelles et prairies. Disponible en ligne http://www.comifer.asso.fr/images/publications/brochures/BROCHURE_AZOTE_20130705eb.pdf (consulté le 08/04/2021)
- Cormier F., Faure S., Dubreuil P., Heumez E., Beauchêne K., Lafarge S., Praud S., Le Gouis J. 2013. A multi-environmental study of recent breeding progress on nitrogen use efficiency in wheat (*Triticum aestivum* L.). *Theoretical and Applied Genetics*, 126, pp. 3035–3048. doi.org/10.1007/s00122-013-2191-9.
- De Benedetto D., Castrignano A., Diacono M., Rinaldi M., Ruggieri S., Tamborrino R., 2013. Field partition by proximal and remote sensing data fusion. *Biosystems Engineering*, 114 (4), pp. 372-383. doi.org/10.1016/j.biosystemseng.2012.12.001.
- Del Pozo S., Rodríguez-González P., Hernández-López D., Felipe-García B., 2014. Vicarious Radiometric Calibration of a Multispectral Camera on Board an Unmanned Aerial System. *Remote Sensing*, 6, pp. 1918-1937. doi.org/10.3390/rs6031918.
- De Souza R., Buchhart C., Heil K., Plass J., Padilla F.M, Schmidhalter U., 2021. Effect of Time of Day

- and SkyConditions on Different Vegetation Indices Calculated from Active and Passive Sensors and Images Taken from UAV. *Remote Sensing*, 13(9), 1691. doi.org/10.3390/rs13091691.
- Degan F. Enquête nationale “fertilisation azotée”: des pratiques plus performantes et efficaces. 2019. *Perspectives agricoles*, 463.
- Demetriades-Shah T.H., Steven M.D., Clark J.A., 1990. High Resolution Derivative Spectra in Remote Sensing. *Remote Sensing and Environment*, 33, pp. 55-64.
- Diacono M., Rubino P., Montemurro F., 2013. Precision nitrogen management of wheat. A review. *Agronomy for Sustainable Development*, 33, pp. 219–241. doi.org/10.1007/s13593-012-0111z.
- Dobermann A., Cassman K.G., 2005. Cereal area and nitrogen use efficiency are drivers of future nitrogen fertilizer consumption. *Science in China. Series C, Life sciences*, 48(2), pp. 745-758. doi.org/10.1007/BF03187115.
- Erdle K., Mistele B., Schmidhalter U., 2011. Comparison of active and passive spectral sensors in discriminating biomass parameters and nitrogen status in wheat cultivars. *Field Crops Research*, 124, 74-84. doi.org/10.1016/j.fcr.2011.06.007.
- ESA. 2021. MultiSpectral Instrument (MSI) Overview. Disponible en ligne : <https://sentinel.esa.int/web/sentinel/technical-guides/sentinel-2-msi/msi-instrument> (consulté le 04/02/22)
- FAO. 2019. World fertilizer trends and outlook to 2022. Disponible en ligne : <http://www.fao.org/3/ca6746en/ca6746en.pdf> (consulté le 27/06/21)
- FAO. 2021. FAOSTAT. Disponible en ligne : <http://www.fao.org/faostat/fr/#compare> (consulté le 30/09/2021)
- Farmstar. 2020. Farmstar fait peau neuve pour ses 20 ans. Disponible en ligne : https://actualites-agricoles.lacooperationagricole.coop/images/files/2020/AA-2020-09-25/Dossier%20de%20presse%20Farmstar%202020_220920.pdf (Consulté le 12/10/2021)
- Ferrante A., Cartelle J., Savin R., Slafer G., 2017. Yield determination, interplay between major components and yield stability in a traditional and a contemporary wheat across a widerange of environments. *Field Crops Research*, 203, pp. 114-127. doi.org/10.1016/j.fcr.2016.12.028.
- Fischer T., Byerlee D., Edmeades G., 2014. Crop yields and global food security, Will yield increase continue to feed the world? ACIAR Monograph No. 158. Australian Centre for International Agricultural Research.
- Foulkes M.J., Slafer G.A., Davies W.J., Berry P.M., Sylvester-Bradley R., Martre P., Calderini D.F., Griffiths S., Reynolds M.P., 2011. Raising yield potential of wheat. III. Optimizing partitioning to grain while maintaining lodging resistance. *Journal of Experimental Botany*, 62(2), pp. 469-486. doi.org/10.1093/jxb/erq300.
- FranceAgriMer. 2020. Blé tendre, fiche filière. Disponible en ligne : <https://www.franceagrimer.fr/fam/content/download/63215/document/FICHE%20FILIERE%20OBLE%20TENDRE.pdf> (consulté le 30/09/2021)

- Fu Z., Jiang J., Gao Y., Krienke B., Wang M., Zhong K., Cao Q., Tian Y., Zhu Y., Cao W., Liu X., 2020. Wheat Growth Monitoring and Yield Estimation based on Multi-Rotor Unmanned Aerial Vehicle. *Remote Sensing*, 12, pp. 508-526. doi.org/10.3390/rs12030508.
- Gabriel J.L., Zarco-Tejada P.J., Lopez-Herrera P.J., Perez-Martin E., Alonso-Ayuso M., Quemada M., 2017. Airborne and ground level sensors for monitoring nitrogen status in a maize crop. *Biosystems Engineering*, 160, pp. 124-133. doi.org/10.1016/j.biosystemseng.2017.06.003.
- Gastal F., Lemaire G., 2002. N uptake and distribution in crops: an agronomical and ecophysiological perspective. *Journal of Experimental Botany*, 53, 370, pp. 789-799. doi.org/10.1093/jexbot/53.370.789.
- Gastal F., Lemaire G., Durand J.L., Louarn G., 2015. Quantifying crop responses to nitrogen and avenues to improve nitrogen-use efficiency. *Crop Physiology*, Chap. 8, pp. 161-206. doi.org/10.1016/B978-0-12-417104-6.00008-X.
- Ge H., Xiang H., Ma F., Li Z., Qiu Z., Tan Z., Du C., 2021. Estimating Plant Nitrogen Concentration of Rice through Fusing Vegetation Indices and Color Moments Derived from UAV-RGB Images. *Remote Sensing*, 13(9), pp. 1620-1638. doi.org/10.3390/rs13091620.
- Giles J., 2005. Nitrogen study fertilizes fears of pollution. *Nature*, 433, 791. doi.org/10.1038/433791a.
- Gitelson A., Rundquist D.C., 2002. Novel Algorithms for Remote Estimation of Vegetation Fraction. *Remote Sensing of Environment*, 8(1), 76-87. doi.org/10.1016/S0034-4257(01)00289-9.
- Gitelson A.A., Kaufman Y.J., Merzlyak M.N., 1996. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*, 58(3), pp. 289-298. doi.org/10.1016/S0034-4257(01)00289-9.
- Gordillo-Salinas V.M., Flores-Magdaleno H., Ortiz-Solorio C.A., Arteaga-Ramírez R., 2021. Evaluation of nitrogen status in a wheat crop using unmanned aerial vehicle images. *Chilean Journal of Agricultural Research*, 81(3), pp. 408-419. doi.org/10.4067/S0718-58392021000300408.
- Haboudane D., Miller J.R., Tremblay N., Zarco-Tejada P.J., Dextraze L., 2002. Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote Sensing of Environment*, 81(2-3), pp. 416-426. doi.org/10.1016/S0034-4257(02)00018-4.
- Haboudane D., Tremblay N., Miller J.R., 2008. Remote Estimation of Crop Chlorophyll Content Using Spectral Indices Derived From Hyperspectral Data. *IEE Transactions on Geoscience and Remote Sensing*, 46(2), pp. 423-437. doi.org/10.1109/TGRS.2007.904836.
- Hansen P.M., Schjoerring J.K., 2003. Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. *Remote Sensing of Environment*, 86, pp. 542-553. doi.org/10.1016/S0034-4257(03)00131-7.
- Hatfield J.L., Gitelson A.A., Schepers J.S., Walthall C.L., 2008. Application of Spectral Remote Sensing for Agronomic Decisions. *Agronomy Journal*, 100(3), pp. 117-131. doi.org/10.2134/agronj2006.0370c.

- Hawkesford M., Horst W., Kichey T., Lambers H., Schjoerring J., Skrumsager Moller I., White P., 2012. Functions of Macronutrients. Marschner's Mineral Nutrition of Higher Plants. 3. ed. Amsterdam : Elsevier, Academic Press. ISBN 978-0-12-384905-2.
- Houlès V., Guérif M., Mary B., 2006. Elaboration of a nitrogen nutrition indicator for winter wheat based on leaf area index and chlorophyll content for making nitrogen recommendations. *European Journal of Agronomy*, 27, 1-11. doi.org/10.1016/j.eja.2006.10.001.
- Huete A.R., 1988. A Soil - Adjusted Vegetation Index (SAVI). *Remote Sensing of Environment*, 25, pp. 295-309. doi.org/10.1016/0034-4257(88)90106-X.
- Jeuffroy M.-H., Bouchard C., 1999. Intensity and Duration of Nitrogen Deficiency on Wheat Grain Number. *Crop Science*, 39, pp. 1385-1393.
- Jeuffroy M.-H., Recous, S., 1999. Azodyn: a simple model simulating the date of nitrogen deficiency for decision support in wheat fertilization. *Eur. J. Agr.* 10, pp. 129–144. doi.org/10.1016/S1161 0301(98)00059-8
- Jiang J., Zheng H., Ji X., Cheng T., Tian Y., Zhu Y., Cao W., Ehsani R., Yao X., 2019. Analysis and Evaluation of the Image Preprocessing Process of a Six-Band Multispectral Camera Mounted on an Unmanned Aerial Vehicle for Winter Wheat Monitoring. *Sensors*, 19, pp. 747-765. doi.org/10.3390/s19030747
- Jinru X., Su B., 2017. Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. *Journal of Sensors*, 1-17. doi.org/10.1155/2017/1353691.
- Justes E., Jeuffroy M., Mary B., 1997. Wheat, barley, and durum wheat. In: Lemaire, G. (Ed.), *Diagnosis of the Nitrogen Status in Crops*. Springer-Verlag, Berlin, Heidelberg, pp. 73–92.
- Justes E., Mary B., Meynard J-M., Machet J-M., Huché-Théliet L., 1994. Determination of a critical nitrogen dilution curve for winter wheat crops. *Annals of Botany*, 74, pp. 397-407. doi.org/10.1006/anbo.1994.1133.
- Karcher D.E., and Richardson M.D., 2003. Quantifying turfgrass color using digital image analysis. *Crop Sciences*, 43, pp. 943–951. doi.org/10.2135/cropsci2003.0943.
- Kaufman Y.J., Tanré D., 1992. Atmospherically Resistant Vegetation Index (ARVI) for EOS-MODIS. *IEEE Transactions on Geoscience and Remote Sensing*, 30 (2), pp. 261-270. doi.org/10.1109/36.134076.
- Knipling E.B., 1970. Physical and Physiological Basis for the Reflectance of Visible and Near-Infrared Radiation from Vegetation. *Remote Sensing of Environment*, 1(3), pp. 155-159. doi.org/10.1016/S0034-4257(70)80021-9.
- Kuska M.T., Behmann J., Mahlein A.-K., 2018. Potential of hyperspectral imaging to detect and identify the impact of chemical warfare compounds on plant tissue. *Pure and Applied Chemistry*, 90(10). doi.org/10.1515/pac-2018-0102.
- Labreuche J., Bureau S., de Bataille H., Duval R., 2013. Une rotation betteravière propice au labour et au semis direct. *Perspectives Agricoles*, 403, pp. 36-40.
- Lachia N. 2020. Usage de la télédétection en agriculture – campagne 2020. Disponible en ligne : <http://agrotic.org/observatoire/> (consulté le 30/09/2021)

- Leip A., Achermann B., Billen G., Bleeker A., Bouwman A., de Vries W., Dragosits U., Doring U., Fernall D., Geupel M., Herolstab j., Johnes P., Le Gall A. C., Monni S., Neveceral R., Orlandini L., Prud'homme M., Reuter H., Simpson D., Seufert G., Spranger T., Sutton M., van Aardenne J., Voss M. and Winiwarter W., 2011. The European Nitrogen Assessment. Cambridge University Press, Cambridge, pp. 345-376. ISBN 9781107006126.
- Lemaire G., 2019. Une nouvelle approche de la fertilisation des cultures. *Agronomie, Environnement & Sociétés*, Association Française d'Agronomie (Afa), 9.
- Lemaire G., Ciampitti I., 2020. Crop mass and N status as prerequisite covariables for unravelling nitrogen use efficiency across genotype-by-environment-by-management scenarios: A Review. *Plants*, 9, pp. 1309-1327. doi.org/10.3390/plants9101309.
- Lemaire G., Gastal F. 1997. N uptake and distribution in crops: an agronomical and ecophysiological perspective. *Journal of Experimental Botany*, 53(370), pp. 789-799. doi.org/10.1093/jexbot/53.370.789.
- Lemaire G., Jeuffroy M.H., Gastal F. 2008., Diagnosis tool for plant and crop N status in vegetative stage theory and practices for crop N management. *Eur. J. Agron*, 28, pp. 614–624. doi.org/10.1016/j.eja.2008.01.005.
- Leroux C. 2018. Comment valider un modèle de prediction ? Disponible en ligne : <https://www.aspexit.com/comment-valider-un-modele-de-prediction/#:~:text=L'erreur%20quadratique%20moyenne%20%3A%20RMSE,R%20M%20S&text=Un%20dernier%20indicateur%20pertinent%20est,%C3%A0%20la%20variance%20du%20mod%C3%A8le>. (consulté le 18/10/2021)
- Li F., Mistele B., Hu Y., Chen X., Schmidhalter U., 2014. Reflectance estimation of canopy nitrogen content in winter wheat using optimised hyperspectral spectral indices and partial least squares regression. *European Journal of Agronomy*, 52, pp. 198-209. doi.org/10.1016/j.eja.2013.09.006.
- Liu Y., Cheng T., Zhu Y., Tian Y., Cao W., Yao X., Wang N., 2016. Comparative analysis of vegetation indices, non-parametric and physical retrieval methods for monitoring nitrogen in wheat using UAV based multispectral imagery. In : *International Geoscience and Remote Sensing Symposium (IGARSS)*, pp. 7362-7365, doi: 10.1109/IGARSS.2016.7730920.
- Machet J.M., Dubrulle P., Damay N., Philippon E., 2012. Azofert. Disponible en ligne : <http://inra-dam-front-resources-cdn.brainsonic.com/ressources/afile/246263-d1766-resource-plaquette-azofert.html> (consulté le 03/06/2016)
- Maes W.H., Steppe K., 2019. Perspectives for Remote Sensing with Unmanned Aerial Vehicles in Precision. *Trends in Plant Science*, 24(2), pp. 152-164. doi.org/10.1016/j.tplants.2018.11.007.
- Makowski D., Brun F., Doutart E., Duyme F., El Jabri M., Fauvel K., Legris M., Philibert A., Piraux F., Ternier A. *Data science pour l'agriculture et l'environnement*. Ellipses: Paris, 2021.
- Manfreda S., McCabe M.F., Miller P.E., Lucas R., Pajuelo Madrigal V., Mallinis G., Ben Dor E., Helman D., Estes L., Ciraolo G., Mullerova J., Tauro F., de Lima M.I., de Lima J.L.M.P. Maltese A., Frances F., Caylor K., Kohv M., Perks M., Ruiz-Perez G, Su Z., Vico G., Toth B., 2018. On the Use of Unmanned Aerial Systems for Environmental Monitoring. *Remote sensing*, 10, pp. 641-668. doi.org/10.3390/rs10040641.

- MAPIR. About Mapir. Disponible en ligne : <https://www.mapir.camera/pages/about-mapir> (consulté le 30/05/2022)
- Masclaux-Daubresse C., Daniel-Vedele F., Dechorgnat J., Chardon F., Gaufichon L., Suzuki A., 2010. Nitrogen uptake, assimilation and remobilization in plants: challenges for sustainable and productive agriculture. *Annals of Botany*, 105, pp. 1141-1157. doi.org/10.1093/aob/mcq028.
- Matese A., Toscano P., Di Gennaro S.F., Genesio L., Vaccari F.P., Primicerio J., Belli C., Zaldei A., Bianconi R., Gioli B., 2015. Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture. *Remote Sensing*, 7, pp. 2971–2990. doi.org/10.3390/rs70302971.
- Mengmeng D., Noburu N., 2017. Monitoring of Wheat Growth Status and Mapping of Wheat Yield's within-Field Spatial Variations Using Color Images Acquired from UAV-camera System. *Remote Sensing*, 9, pp. 289-312. doi.org/10.3390/rs9030289.
- Meynard J.M., Cerf M., Guichard L., Jeuffroy M.H., Makowski D., 2002. Which decision support tools for the environmental management of nitrogen? *Agronomie*, 22, pp. 817-829. doi.org/10.1051/agro:2002064.
- Meynard J.M., Jeuffroy M.H., 2019. 50 ans de méthode du Bilan : progrès passés et limites actuelles. *Agronomie, Environnement et Sociétés*, 9(1), 45-54.
- Miller A.J. et Cramer M.D., 2004. Root Nitrogen Acquisition and Assimilation. *Plant and Soil*, 274, pp. 1-36. doi.org/10.1007/s11104-004-0965-1.
- Ministère de l'agriculture, de l'agroalimentaire et de la forêt. Recensement et analyse des outils de raisonnement dynamique et de pilotage de la fertilisation azotée. Rapport [en ligne], 2015, 81 p. Disponible en ligne : http://www.comifer.asso.fr/images/bilan-azote/outils-de-pilotage/2016_Rapport_OAD_Pilotage_Ferti_SCE.pdf (Consulté le 26/04/2018)
- Morot-Gaudry, J.F., 1997. Assimilation de l'azote chez les plantes : Aspects physiologique, biochimique et moléculaire. INRA Editions, 422 p., Mieux Comprendre.
- Mountrakis G., Im J., Ogole C., 2011. Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), pp. 247-259. doi.org/10.1016/j.isprsjprs.2010.11.001.
- Muñoz-Huerta R.F., Guevara-Gonzalez R.G., Contreras-Medina L.M., Torres-Pacheco I., Prado-Olivarez J., Ocampo-Velazquez R.V., 2013. A Review of Methods for Sensing the Nitrogen Status in Plants: Advantages, Disadvantages and Recent Advances. *Sensors*, 13, pp. 10823-10843. doi.org/10.3390/s130810823.
- Naud C., Makowski D., Jeuffroy M.-H., 2009. Leaf transmittance measurements can improve predictions of the nitrogen status for winter wheat crop. *Field Crops Research* 110, pp. 27–34. doi.org/10.1016/j.fcr.2008.06.012.
- Niu Q., Feng H., Li C., Yang G., Fu Y., Li Z., Pei H., 2019. Estimation of leaf nitrogen concentration of winter wheat using uav-based RGB imagery. *IFIP Advances in Information and Communication Technology*, 546, pp. 139-153. doi.org/10.1007/978-3-030-06179-1_15.
- Omara P., Aula L., Oyebiyi F., Raun W.R., 2019. World Cereal Nitrogen Use Efficiency Trends: Review and Current Knowledge. *Agrosystems, Geosciences & Environment*, 2 (1). doi.org/10.2134/age2018.10.0045.

- Orloff S., Wright S., Ottman M. 2012. Nitrogen management impacts on wheat yield and protein. In : Proceedings of California Alfalfa & Grains Symposium, Sacramento, CA, December
- Padilla F.M., Gallardo M., Pena-Fleitas M.T., De Souza R., Thompson R., 2018. Proximal optical sensors for nitrogen management of vegetable crops: A review. *Sensors*, 2083, pp. 1-23. doi.org/10.3390/s18072083.
- Pancorbo J.L., Camino C., Alonso-Ayuso M., Raya-Sereno M.D., Gonzalez-Fernandez I., Gabriel J.L., Zarco-Tejada P.J., Quemada M., 2021. Simultaneous assessment of nitrogen and water status in winter wheat using hyperspectral and thermal sensors. *European Journal of Agronomy*, 127. doi.org/10.1016/j.eja.2021.126287.
- Pellerin S., Butler F., Van Laethem C., 2014. Fertilisation et environnement, quelles pistes pour l'aide à la décision. Quae Editions. ISBN 978-2-7592-2055-7.
- Quemada M., Pancorbo J.L., Alonso-Ayuso M., Gabriel J.L., Lopez-Herrera J, Perez-Martin E. Vegetation indices from remote sensing imagery as proxies for yield and grain N in wheat. In: Precision Agriculture '19: Proceedings of the 12th European Conference on Precision Agriculture, edited by J.V. Stafford, BIOS Scientific Publishers Ltd, Oxford, UK, 323-330.
- Ravier C., Jeuffroy M.H., Gate P., Cohan P., Meynard J.M., 2018. Combining user involvement with innovative design to develop a radical new method for managing N fertilization. *Nutrient Cycling in Agroecosystems*, 110(4), pp. 117–134. doi.org/10.1007/s10705-017-9891-5.
- Ravier C., Jeuffroy M.H., Meynard J.M., 2016. Mismatch between a science-based decision tool and its use: The case of the balance-sheet method for nitrogen fertilization in France. *NJAS Wageningen J. Life Sci.* 79, pp. 31–40. doi:10.1016/j.njas.2016.10.001.
- Ravier C., Meynard J.M., Cohan J.P., Gate P., Jeuffroy M.H., 2017a. Early nitrogen deficiencies favor high yield, grain protein content and N use efficiency in wheat. *European Journal of Agronomy*, 89, 16–24. doi.org/10.1016/j.eja.2017.06.002.
- Ravier C., Quemada M., Jeuffroy M.-H., 2017b. Use of a chlorophyll meter to assess nitrogen nutrition index during the growth cycle in winter wheat. *Field Crops Research*, 214, pp. 73-82. doi.org/10.1016/j.fcr.2017.08.023.
- Ravier C., Sabatier R., Beillouin D., Meynard J.M., Trépos R., Jeuffroy M.H., 2021. Decision rules for managing N fertilization based on model simulations and viability assessment. *European Journal of Agronomy*. 125 , pp.126247. doi.org/10.1016/j.eja.2021.126247.
- Reujean J., and Breon F., 1995. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of Environment*, 51, pp. 375–384. doi.org/10.1016/0034-4257(94)00114-3.
- Rondeaux G., Steven M., Baret F., 1996. Optimization of Soil-Adjusted Vegetation Indices. *Remote Sensing of Environment*, 55, pp. 95-107. doi.org/10.1016/0034-4257(95)00186-7.
- Rorie R.L., Purcell L.C., Mozaffari M., Karcher D.E., King C.A., Marsh M.C. and Longer D.E., 2011. Association of “Greenness” in Corn with Yield and Leaf Nitrogen Concentration. *Agronomy Journal*, 103, pp. 529-535. doi.org/10.2134/agronj2010.0296.
- Rousse J.W., Haas R.H., Schell J.A., Deering D.W., 1973. Monitoring vegetation systems in the great plains with ERTS. ERTS symposium, NASA, SP-351, Washington DC 1 309-317.

- Schirrmann M., Giebel A., Gleiniger F., Pflanz M., Lentschke J., Dammer K.H., 2016. Monitoring Agronomic Parameters of Winter Wheat Crops with Low-Cost UAV Imagery. *Remote Sensing*, 8(9):706. doi.org/10.3390/rs8090706.
- Sharma L.K., Bali S.K., 2018. A review of methods to improve nitrogen use efficiency in agriculture. *Sustainability*, 10 (51). doi.org/10.3390/su10010051.
- Sieling K., Beims S., 2007. Effects of 15N Split-application on Soil and Fertiliser N Uptake of Barley, Oilseed Rape and Wheat in Different Cropping Systems. *Journal of Agronomy and Crop Science*, 193, pp. 10-20. doi.org/10.1111/J.1439-037X.2006.00238.X.
- Sieling K., Kage H., 2021. Apparent fertilizer N recovery and the relationship between grain yield and grain protein concentration of different winter wheat varieties in a long-term field trial. *European Journal of Agronomy*, 124, 126246. doi.org/10.1016/j.eja.2021.126246.
- Slafer G.A., Sadras V.O., Savin R., no date. Is compensation between yield components in wheat a feedback process of responses to availability of resources?
- Slafer G.A., Savin R., Sadras V.O., 2014. Coarse and fine regulation of wheat yield components in response to genotype and environment. *Field Crops Research*, 157, pp. 71-83. doi.org/10.1016/j.fcr.2013.12.004.
- Soenen S., Bessard-Duparc P., Laberdesque M., Piquemal B., Cohan J.P., Le Bris X., 2017. Dynamisation du bilan d'azote avec le modèle de culture CHN pour un raisonnement en temps réel. Congrès GEMAS-COMIFER Nantes-France, 08 & 09 novembre 2017
- Späti K., Huber R., Finger R., 2021. Benefits of Increasing Information Accuracy in Variable Rate Technologies. *Ecological Economics*, 185(8). doi.org/10.1016/j.ecolecon.2021.107047
- Sripada R., Heiniger R., White J. & Meijer A., 2006. Aerial colorinfrared photography for determining early in-season nitrogen requirements in corn. *Agronomy Journal*, 98, 968–977. doi.org/10.2134/agronj2005.0200
- Sutton M.A., Billen G., Bleeker A., Erisman J.W., Greenfelt P, Grinsven H; Grizzetti B., Howard C., Leip A., 2010. European nitrogen assessment - Technical summary. *European Nitrogen Assessment*. XXXV-LI.
- Tremblay N., Fallon E., Ziadi N., 2011. Sensing of crop nitrogen status: opportunities, tools, limitations, and supporting information requirements. *Proceedings of the European Society for Agronomy Congress*, Bologna, Italy.
- Unifa. 2019. Le cycle de l'azote. Disponible en ligne : <https://fertilisation-edu.fr/cycles-bio-geo-chimiques/le-cycle-de-l-azote-n.html> (Consulté le 10/07/2021)
- Vance C.P., 2001. Symbiotic nitrogen fixation and phosphorus acquisition: plant nutrition in a world of declining renewable resources. *Plant Physiology* 127, pp. 390–397. doi.org/10.1104/pp.010331.
- Wang H., Mortensen A.K., Mao P., Boelt B., Gislum R., 2019. Estimating the nitrogen nutrition index in grass seed crops using a UAV-mounted multispectral camera. *International Journal of Remote Sensing*, 40 (7), pp. 2467-2482. doi.org/10.1080/01431161.2019.1569783

- Yang B., Wang M., Sha Z., Wang B., Chen J., Yao X., Cheng T., Cao W., Zhu Y., 2019. Evaluation of aboveground nitrogen content of winter wheat using digital imagery of unmanned aerial vehicles. *Sensors*, 19, pp. 4416-4433. doi.org/10.3390/s19204416.
- Yao X., Huang Y., Shang G., Zhou C., Cheng T., Tian Y., Cao W., Zhu Y. 2015. Evaluation of six algorithms to monitor wheat leaf nitrogen concentration. *Remote Sens.*, 7, pp. 14939-14966. doi.org/10.3390/rs71114939.
- Zadoks J.C., Chang T., Konzak C.F. 1974., A decimal code for the growth stages of cereals. *Weed Research*, 14, pp. 415-421.
- Zheng H., Li W., Jiang J., Liu Y., Cheng T., Tian Y., Zhu Y., Cao W., Zhang Y., Yao X., 2018. A comparative assessment of different modeling algorithms for estimating leaf nitrogen content in winter wheat using multispectral images from an unmanned aerial vehicle. *Remote Sensing*, 10, pp. 2026-2041. doi.org/10.3390/rs10122026.


Annexes

Annexe 1: Indices de végétations calculés dans des études portant sur l'estimation du statut azoté du blé à partir d'images prises par drone ou satellite (RapidEye), et longueurs d'onde utilisées en fonction des caméras.


IV	400	436	450	490	515	531	539	546	550	555	570	658	660	670	675	700	710	720	730	735	750	790	800	805	850	860	Références	Caméra
NDVI														X									X				Quemada et al., 2019 (ECPA)	RedEdge-Micasense
												X												X			Basso et al., 2015	rapidEye
														X									X				Gabriel et al., 2017	VNIR et MCA-6 Tetracam
													X										X				Argento et al., 2020	Sequoia
															X											X	Gordillo-Salinas et al., 2021	Canon S110 modified NIR
																X									X		Fu et al., 2020	Airphen
NDRE																		X					X				Quemada et al., 2019 (ECPA)	RedEdge-Micasense
																			X						X		Fu et al., 2020	Airphen
																				X		X					Argento et al., 2020	Sequoia
NDRE1												X												X			Basso et al., 2015	rapidEye
NDRE2												X					X										Basso et al., 2015	rapidEye
TCARI									X					X		X											Quemada et al., 2019 (ECPA)	RedEdge-Micasense
										X		X					X										Basso et al., 2015	rapidEye
								X						X		X											Gabriel et al., 2017	VNIR et MCA-6 Tetracam
OSAVI														X									X				Quemada et al., 2019 (ECPA)	RedEdge-Micasense

											X												X			Basso et al., 2015	rapidEye
													X										X			Gabriel et al., 2017	VNIR et MCA-6 Tetracam
														X										X		Fu et al., 2020	Airphen
DCNI														X		X		X								Quemada et al., 2019 (ECPA)	RedEdge-Micasense
														X		X		X								Gabriel et al., 2017	VNIR et MCA-6 Tetracam
MTVI									X														X			Basso et al., 2015	rapidEye
MTVI2								X		X													X			Basso et al., 2015	rapidEye
CMR									X														X			Basso et al., 2015	rapidEye
CGM								X															X			Basso et al., 2015	rapidEye
CVI								X		X													X			Basso et al., 2015	rapidEye
MTCI									X							X							X			Basso et al., 2015	rapidEye
CARI								X		X						X										Basso et al., 2015	rapidEye
MCARI								X		X						X										Basso et al., 2015	rapidEye
MCARI2								X		X													X			Basso et al., 2015	rapidEye
RDVI													X										X			Gabriel et al., 2017	VNIR et MCA-6 Tetracam
Red Edge Reflexion Index																X									X	Gabriel et al., 2017	VNIR et MCA-6 Tetracam
PRI						X																				Gabriel et al., 2017	VNIR et MCA-6 Tetracam
PRI normalisé				X	X																					Gabriel et al., 2017	VNIR et MCA-6 Tetracam


BG1	X						X														Gabriel et al., 2017	VNIR et MCA-6 Tetracam
BG2		X					X														Gabriel et al., 2017	VNIR et MCA-6 Tetracam
MGRVI						X							X								Yang et al., 2019	Sony EXMOR
RGBVI	X					X							X								Yang et al., 2019	Sony EXMOR
GRVI						X							X								Yang et al., 2019	Sony EXMOR
GLA	X					X							X								Yang et al., 2019	Sony EXMOR
Exces R						X							X								Yang et al., 2019	Sony EXMOR
Exces G	X					X							X								Yang et al., 2019	Sony EXMOR
Exces B	X					X															Yang et al., 2019	Sony EXMOR
CIVE	X					X							X								Yang et al., 2019	Sony EXMOR
VARI	X					X							X								Yang et al., 2019	Sony EXMOR
GNDVI										X											Fu et al., 2020	Airphen
							X											X			Argento et al., 2020	Sequoia
RVI													X								Fu et al., 2020	Airphen
CIRE															X						Fu et al., 2020	Airphen
SAVI					X								X								Fu et al., 2020	Airphen
RESAVI															X						Fu et al., 2020	Airphen



Annexe 2 : régressions linéaires simples entre les IV minimisant le RMSE par formulation lorsque les jeux de données de 2020 et 2021 sont combinés au stade 2N



Annexe 3 : INN prédit en fonction de l'INN mesuré pour les jeux de données 2020 et 2021 combinés au stade 2 nœuds (Z32), à gauche sur le jeu de données d'entraînement (75%) et sur le jeu de données de validation à droite (25%), pour le modèle PLS construit avec les combinaisons qui minimisent le RMSE par formulation d'indice de végétation



Annexe 4 : INN prédit en fonction de l'INN mesuré pour les jeux de données 2020 et 2021 combinés au stade 2 nœuds (Z32), à gauche sur le jeu de données d'entraînement (75%) et sur le jeu de données de validation à droite (25%), pour le modèle PLS construit avec les combinaisons qui minimisent le RMSE sélectionnées d'après un RMSE seuil de 0.179