



HAL
open science

Commande Prédicative optimale temps-réel, appliquée au contrôle de véhicules automobiles hybrides connectés à leurs environnements

Hamza Idrissi Hassani Azami

► To cite this version:

Hamza Idrissi Hassani Azami. Commande Prédicative optimale temps-réel, appliquée au contrôle de véhicules automobiles hybrides connectés à leurs environnements. Autre. Institut National Polytechnique de Toulouse - INPT, 2018. Français. NNT : 2018INPT0105 . tel-04223314

HAL Id: tel-04223314

<https://theses.hal.science/tel-04223314v1>

Submitted on 29 Sep 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.



Université
de Toulouse

THÈSE

En vue de l'obtention du

DOCTORAT DE L'UNIVERSITÉ DE TOULOUSE

Délivré par :

Institut National Polytechnique de Toulouse (Toulouse INP)

Discipline ou spécialité :

Systemes Embarqués

Présentée et soutenue par :

M. HAMZA IDRISSE HASSANI AZAMI

le jeudi 22 novembre 2018

Titre :

Commande Prédictive Optimale temps-réel, appliquée au contrôle de
Véhicules Automobiles Hybrides connectés à leurs environnements

Ecole doctorale :

Systemes (Systemes)

Unité de recherche :

Laboratoire Plasma et Conversion d'Energie (LAPLACE)

Directeur(s) de Thèse :

M. STEPHANE CAUX

M. FREDERIC MESSINE

Rapporteurs :

M. ELIGIUS HENDRIX, UNIVERSIDAD DE MALAGA

Mme DANIELA CHRENKO, UNIV TECHNO BELFORT MONTBELIAR

Membre(s) du jury :

Mme MIREILLE JACOMINO, INP DE GRENOBLE, Président

M. ALAIN BOUSCAYROL, UNIVERSITE LILLE 1, Membre

M. FREDERIC MESSINE, INP TOULOUSE, Membre

M. STEPHANE CAUX, INP TOULOUSE, Membre

Remerciements

Je tiens à remercier Frédéric MESSINE et Stéphane CAUX, Professeurs à l'INP-ENSEEIH, qui m'ont encadré tout au long de cette thèse et qui l'ont enrichi par leurs connaissances. Qu'ils soient aussi remerciés pour leur gentillesse, leur disponibilité permanente et pour les nombreux encouragements qu'ils m'ont prodigués.

Je remercie Mariano SANS (Continental Automotive) d'avoir placé sa confiance en moi pour mener à bien ce projet de recherche. Je tiens aussi à le remercier pour sa précieuse contribution à l'évaluation de ce travail.

J'adresse mes remerciements aux ingénieurs de Continental Automotive, Paul BOUCHARREL et Hervé DUPOND, pour leur accompagnement lors de l'utilisation des modèles et outils de l'entreprise.

Merci aux ingénieurs de l'IAM-TUD (Université de Dresde-Allemagne), Steffen KUTTER, Stephan UEBEL et Conny TEMPELHAHN, avec lesquels j'ai passé trois mois de collaboration fructueuse. Je remercie l'IAM-TUD pour avoir permis l'utilisation de leurs bases de données.

J'exprime ma gratitude à Daniela CHRENKO (Université de Bourgogne), Eligius HENDRIX (University of Malaga), Mireille JACOMINO (Grenoble INP), et Alain BOUSCAYROL (Université de Lille 1) qui ont bien voulu participer au jury et examiner cette thèse.

Merci à l'ADEME pour le financement de cette thèse, ainsi qu'à Matthieu MEFFLET-PIPERREL, référent ADEME, pour son accompagnement. Mes remerciements à Continental Automotive également pour le co-financement de cette thèse.

Enfin, je tiens à remercier mes parents qui m'ont permis d'être là où je suis aujourd'hui, ainsi que mon épouse qui m'a soutenu durant ces 3 ans de thèse.

Table des matières

Table des sigles et acronymes	xiii
Introduction	1
1 Etat de l'art	11
1.1 Méthodes à base de règles	13
1.2 Méthodes basées sur l'optimisation	16
1.3 Contribution : Le Principe du Maximum de Pontryagin appliqué en temps-réel avec des prédictions probabilistes	26
2 Modélisation sous forme de problème de contrôle optimal	29
2.1 Architectures hybrides parallèles	31
2.2 Modélisation du problème de l' <i>Energy Management</i>	42
3 PMP Energy Management déterministe	49
3.1 Résolution du problème de contrôle optimal	50
3.2 Structure algorithmique du <i>PMP Energy management</i>	61
3.3 Évaluation du <i>PMP Energy Management</i> par simulation	66
4 PMP Energy Management Probabiliste	81
4.1 Incertitude des prédictions et influence sur l'état de charge de la batterie . . .	81
4.2 Modélisation probabiliste	83
4.3 Comparaison des méthodes : Déterministe versus Probabiliste	107
4.4 Conclusions	109
Conclusion	111
A Cycles et trajets	115

B	Modèle AMESim de la Ford Focus	119
C	Calcul d'émissions CO_2 équivalentes	121
	Bibliographie	129
	Résumé	131

Table des figures

1	Emissions CO_2 par secteur d'activités en 2015. <i>Source</i> : [1]	1
2	Répartition des émissions CO_2 dans le secteur du transport. <i>Source</i> : [1] . . .	1
3	Emissions atmosphérique de CO_2 en France métropolitaine entre 1960 et 2016, en Mt. <i>Source</i> : [2]	2
4	Répartition des ventes de véhicules par types d'énergie en France en 2016. <i>Source</i> : <i>Evolution des marchés, caractéristiques environnementales et techniques, ADEME 2017</i>	3
5	Augmentation des ventes d'HEV entre 2016 et 2017. <i>Source</i> : ACEA	4
6	Schéma de l'architecture du <i>Woods Dual Power</i> , véhicule hybride construit en 1917. <i>Source</i> : [4]	5
7	Classification des architectures des véhicules hybrides électriques. <i>Source</i> : [8]	7
1.1	Représentation graphique des publications par année d'articles sur les méthodes d'Energy Management. <i>Source</i> : [11]	12
1.2	Classification des méthodes de l' <i>Energy management</i>	13
1.3	Schéma bloc général d'un Model-Predictive Control. <i>Source</i> : [77]	24
1.4	Entrée/Sortie lors d'une itération d'un contrôle MPC <i>Source</i> : [77]	25
2.1	Schéma de l'architecture d'une chaîne de traction série d'un véhicule hybride	29
2.2	Schéma de l'architecture d'une chaîne de traction parallèle d'un véhicule hybride	30
2.3	Différentes architectures hybrides selon la position de la machine électrique dans la chaîne de traction	31
2.4	Schéma de l'architecture de la Ford Focus GTC2 48V	33
2.5	Cartographie de variation de la tension à vide de la batterie 48V de la Ford Focus GTC2	34
2.6	Cartographie de variation de la résistance interne de la batterie de la Ford Focus GTC2 48V	35
2.7	Cartographies des variations de la tension de polarisation de la batterie 48V de la Ford Focus GTC2	35

2.8	Circuit électrique de la batterie de la Ford Focus GTC2 48V	36
2.9	Puissance électrique consommée par l'EMA et l'onduleur en fonction du couple fourni et de la vitesse du moteur à 48V	37
2.10	Puissance thermique consommée par l'ICE fonction du couple fourni et de la vitesse du moteur dans la Ford Focus GTC2	38
2.11	Schéma de l'architecture de l'Audi A2 Hybride 330V	39
2.12	Variation de la tension à vide de la batterie de l'Audi A2 Hybride 330V	39
2.13	Circuit électrique de la batterie de l'Audi A2 Hybride 330V	40
2.14	Puissance électrique consommée par l'EMA et l'onduleur en fonction du couple fourni et de la vitesse du moteur à 330V.	40
2.15	Puissance thermique consommée par l'ICE fonction du couple fourni et de la vitesse du moteur dans l'Audi A2 Hybrid	41
3.1	Pourcentage de $\frac{P_{elec}}{V_{bat}}$ que représente $\frac{\partial P_{elec}}{\partial V_{bat}}$, pour l'EMA de la Ford Focus à 48V, en fonction des couples et vitesses de rotation.	52
3.2	Monotonie de f : Variation de l'état de charge final en fonction du co-état initial sur les trajets NEDC, WLTC et RDE95 avec la Ford Focus 48V et la Audi A2	60
3.3	Schéma de l'algorithme de tirs avec dichotomie	62
3.4	Fonction f : Calcul de l'état de charge final en fonction de l'initialisation du co-état, et des prédictions.	63
3.5	Minimisation de l'Hamiltonien en temps réel en fonction des états réels du système et de l'initialisation du co-état.	64
3.6	Séquencement des tâches du PMP Energy management embarqué.	65
3.7	Variation de $\int \frac{\partial H}{\partial SoC}$ le long des trajets simulés, pour les deux formulations à état adjoint variable	68
3.8	Variations des différences des coefficients de pondération de l'Hamiltonien entre les formulations 1, 2 et la formulation 3	69
3.9	Moyennes et écarts types du coefficient de pondération α pour les trois formulation du <i>PMP Energy Management</i>	70
3.10	Trajectoires de <i>SoC</i> sur les différents trajets simulés, avec PMP et DP	71

3.11	Sur-consommation due à la diminution de l'horizon de prédiction	72
3.12	Trajectoires de SoC avec différents durée de l'horizon de prédiction.	73
3.13	Schéma de l'échange de données entre Matlab/Simulink et AMESim lors de la co-simulation du <i>PMP Energy Management</i> sur la Ford Focus GTC2 48V. . .	74
3.14	Schéma résumant le principe de mise à jour du coefficient de pondération α dans la méthode CostBased.	75
3.15	Evolution de l'état de charge de la batterie sur le trajet Falkenstein avec les méthodes PMP et CostBased.	78
4.1	Demandes du conducteur VS Prédiction des demandes	82
4.2	Trajectoires de <i>SoC</i> avec prédictions précises/imprécises	82
4.3	Fonction de tirs probabiliste \hat{f} : Calcul de la distribution de probabilités de l'état de charge final en fonction de l'initialisation du co-état, et des distributions de probabilités des prédictions	86
4.4	Schéma de l'algorithme de tirs probabiliste avec dichotomie	88
4.5	Distribution de probabilités de la puissance électrique pour des entrées normalement distribuées	89
4.6	Moyennes et écarts types des demandes de vitesses et couples générés à partir des enregistrements Horscha	91
4.7	Évolution de la moyenne et de l'écart type de l'état de charge \hat{SoC} prédits par l'algorithme de tirs probabiliste sur le trajet Horscha avec des distributions normalement distribuées	92
4.8	Distribution de probabilités statistique à partir des 100 simulations comparée à la distribution de probabilités prédite par l'algorithme de probabilité. . . .	92
4.9	États de charges finaux issus de la simulation des 14 trajets Horscha avec l'initialisation du co-état du Test numérique 1 (Distributions normales) . . .	93
4.10	Comparaison de la distribution de probabilités prédite par l'algorithme de tirs et la distribution donnée par les simulations sur les trajets réel en fonction de l'Horizon de prédiction	94
4.11	Trajectoires de <i>SoC</i> issues du PMP probabiliste appliqué sur le premier enregistrement Horscha avec différents horizons de prédictions	95

4.12	Partie urbaine du trajet Horscha : Sur-consommation de carburant, erreurs en état de charge final, et sur-émissions de CO_2 équivalent, en fonction de l'horizon de prédiction.	96
4.13	Trajectoires de SoC sur un trajet Horscha en utilisant différents horizons de prédiction	97
4.14	Partie extra-urbaine du trajet Horscha avec prédictions normalement distribuées : Sur-consommation de carburant, erreurs en état de charge final, et sur-émissions de CO_2 équivalent, en fonction de l'horizon de prédiction.	98
4.15	Comparaison des émissions de CO_2 avec PMP probabiliste et prédictions normalement distribuées : Parties urbaines vs Partie extra-urbaine.	99
4.16	Illustration d'une partie de la matrice de transition des prédictions des demandes de couples et vitesses sur le trajet Horscha.	100
4.17	Trajet générée à partir du modèle de Markov obtenu à partir des enregistrements Horscha.	101
4.18	Distribution de probabilités prédite par l'algorithme de tirs probabiliste avec distribution modélisée par chaîne de Markov.	102
4.19	Distribution de probabilités statistique comparée à la distribution de probabilités prédite par l'algorithme de tirs.	103
4.20	Etats de charge finaux issus de la simulation des 14 trajets Horscha avec l'initialisation du co-état du Test numérique 1 (chaînes de Markov).	103
4.21	Partie urbaine du trajet Horscha avec prédiction en chaînes de Markov : Sur-consommations de carburant, erreurs en état de charge final et sur-émissions de CO_2 équivalent, en fonction de l'horizon de prédiction.	104
4.22	Partie extra-urbaine du trajet Horscha avec prédictions en chaîne de Markov : Sur-consommations de carburant, erreurs en état de charge final, et sur-émissions de CO_2 équivalent, en fonction de l'horizon de prédiction.	105
4.23	Comparaison des émissions de CO_2 entre des prédictions en chaînes de Markov et des prédictions normalement distribuées.	106
4.24	Comparaison des émissions de CO_2 sur les parties urbaines et extra-urbaines des trajets Horscha : Déterministe idéal versus Déterministe versus Probabiliste	107
4.25	Comparaison des trajectoires de SoC sur les trajets Horscha : Déterministe idéal versus Déterministe versus Probabiliste	108
A.1	Vitesse du véhicule en km/h lors du cycle NEDC	116

A.2	Vitesse du véhicule en <i>km/h</i> lors du cycle WLTC	116
A.3	Vitesse du véhicule en <i>km/h</i> lors du cycle JC08	116
A.4	Vitesse du véhicule en <i>km/h</i> lors du cycle RDE95	117
A.5	Vitesse du véhicule en <i>km/h</i> lors du cycle Artemis	117
A.6	Vitesse du véhicule en <i>km/h</i> lors du trajet RCC	117
A.7	Vitesse du véhicule en <i>km/h</i> lors du trajet Falkenstein	118
A.8	Vitesse du véhicule en <i>km/h</i> lors des 14 enregistrements du trajet Horscha . .	118
B.1	Schéma du Modèle de Continental sur le logiciel de simulations multi-physique AMESim de la Ford Focus GTC2.	119

Liste des tableaux

2.1	Description générale des différentes architectures hybrides parallèles selon la position de la machine électrique dans la chaîne de traction.	32
2.2	Valeurs des paramètres électriques pour les différents degrés d'hybridation . .	32
2.3	Fonctionnalités disponibles pour les différents degrés d'hybridation	32
2.4	Valeurs des paramètres principaux utilisés pour le modèle Audi/Ford.	42
3.1	Commande de l'embrayage C_0 optimale en fonction du signe de λ_0	56
3.2	Commande optimale du problème de l' <i>Energy management</i> en fonction de la formulation utilisée	57
3.3	Paramètres du <i>PMP Energy management</i> lors des simulations sur le modèle de référence.	66
3.4	Résultats de consommation en grammes avec le modèle de référence pour les 3 formulations du <i>PMP Energy management</i> en comparaison avec un algorithme de DP.	67
3.5	Paramètres du PMP Energy management lors des co-simulations avec le modèle AMESim de la Ford Focus GTC2 48V	75
3.6	Résultats des co-simulations sur Ford Focus GTC2 48V avec PMP et CostBased. 77	
3.7	Résultats des simulations sur cycle urbain du <i>PMP Energy Management</i> avec 4 initialisations différentes : émissions CO_2 équivalentes comparées au résultat Costbased.	77
3.8	Résultats des co-simulations sur Ford Focus GTC2 48V avec PMP et CostBased : Utilisation de l'énergie électrique	78
4.1	Paramètres du PMP Energy management probabiliste lors des simulations de validation des distributions normalement distribuées	91
4.2	Paramètres du PMP probabiliste lors des simulations de validation des distributions en chaînes de Markov.	102

Table des sigles et acronymes

ADEME	Agence De l'Environnement et de la Maîtrise de l'Energie
GIEC	Groupe d'Experts Intergouvernemental sur l'Evolution du Climat
IEA	International Energy Agency
CITEPA	Centre Interprofessionnel Technique d'Etudes de la Pollution Atmosphérique
SECTEN	SECTeurs Economiques et Energie
ACEA	Association des Constructeurs Européens d'Automobiles
HEV	Hybrid Electrical Vehicles
PHEV	Plug-in Hybrid Electrical Vehicles
ICE	Internal Combustion Engine - Moteur à combustion interne
EMA	Electric Machine Actuator - Moteur électrique
PMP	Principe du Maximum de Pontryagin
ECMS	Equivalent Consumption Minimization Strategy
MPC	Model Predictive Control
DP	Dynamic Programming
SMPC	Stochastic Model Predictive Control
FEAD	Front-End Accessory Drive
IAM	Institute of Automotive Mechatronics- TU Dresden

Nomenclature

β	Rapport de transmission de la courroie []
\hat{f}	Fonction de tir probabiliste
\hat{X}	Variable aléatoire X
λ	État adjoint dans le problème du contrôle optimal
τ	Matrice de transition de la chaîne de Markov
C_0	Commande de d'embrayage []
f	Fonction de tir déterministe
H	Hamiltonien du problème de contrôle optimal
I_{bat}	Courant en sortie de la batterie [A]
I_{DCDC}	Courant en sortie du DCDC [A]
K_i, K_p	Gains du correcteur du DCDC
N_{ema}	Vitesse de rotation de l'EMA [tours/min]
N_{ice}	Vitesse de rotation de l'ICE [tours/min]
OCV	Tension à vide de la batterie [V]
p_X	Densité de probabilités de \hat{X}
P_{aux}	Puissance du réseau auxiliaire 12V [W]
P_{elec}	Puissance thermique consommée par l'ICE [W]
P_{elec}	Puissance électrique consommée par l'EMA [W]
Q_{max}	Charge maximale de la batterie [A.h]
R_{int}	Résistance interne de la batterie [Ω]
SoC	Etat de charge de la batterie (State Of Charge) [%]
T	Horizon de prédiction [s]
T_f	Durée du trajet globale [s]
Tq_{clu}	Couple sur l'arbre moteur (torque to clutch) [N.m]
Tq_{ema}	Couple en sortie de l'EMA [N.m]
Tq_{ema}^{max}	Couple maximal de l'EMA [N.m]
Tq_{ema}^{min}	Couple minimal de l'EMA [N.m]
Tq_{ice}	Couple en sortie de l'ICE [N.m]
Tq_{ice}^{max}	Couple maximal de l'ICE [N.m]

Tq_{ice}^{min}	Couple minimal de l'ICE [N.m]
V_{bat}	Tension de la batterie [V]
V_{ohm}	Chute de tension ohmique dans la batterie [V]
V_{pol}	Tension de polarisation de la batterie [V]
X_{12V}	Grandeurs électriques relatives aux réseau 12V du Ford Focus
EMA	Moteur électrique (Electric Machine Actuator)
ICE	Moteur à combustion interne (Internal Combustion Engine)

Introduction générale

Les émissions de gaz à effet de serre sont une cause directe du changement climatique et le premier rapport d'évaluation du GIEC prévoit que les concentrations de dioxyde de carbone (CO_2) seraient doublées entre 2025 et 2050 sans modification significative de l'activité humaine. De plus, le cinquième rapport d'évaluation du GIEC a démontré que ce sont les gaz à effet de serre et le dioxyde de carbone émis par les combustions fossiles qui ont le plus d'impact sur le réchauffement climatique. Devant ces constatations, une des préoccupations prioritaires pour la survie humaine et celle de la planète en général, est la réduction des émissions des gaz à effet de serre, et particulièrement les émissions de CO_2 .




FIGURE 1 – Emissions CO_2 par secteur d'activités en 2015. *Source* : [1]

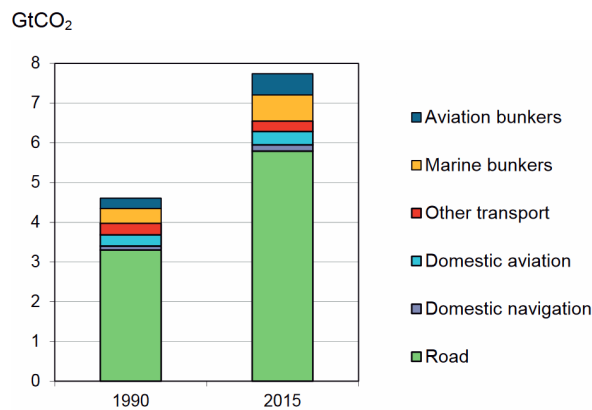


FIGURE 2 – Répartition des émissions CO_2 dans le secteur du transport. *Source* : [1]

L'IEA classe le secteur du transport comme le deuxième plus émetteur de CO_2 en 2015 dans le monde (Figure 1). Le secteur du transport est responsable de 24% des émetteurs des gaz à effet de serre. Seule la production d'énergie électrique et thermique en émet plus. De plus, comme illustré par la Figure 2, les émissions de CO_2 des véhicules automobiles routiers peuvent être estimées à 80% des émissions dues au transport.

En France, le CITEPA dans son rapport SECTEN 2017 [2], place le secteur du transport en tête des émissions de CO_2 en 2017. Plus particulièrement, les émissions des véhicules diesels des particuliers constituent la majorité de ces émissions, avec une part de 16%, tandis que les émissions des véhicules de services représentent 15.1%. En somme, 31.1% des émissions sont issues de l'utilisation des véhicules automobiles, loin devant les 15% du secteur résidentiel et les 7.7% du tertiaire. Dans la Figure 3 issue du rapport du CITEPA, on peut constater l'évolution croissante de la part que prend le secteur du transport dans les émissions de CO_2 en France. Dans les années soixante, les émissions dues au transport étaient minoritaires juste devant le secteur de l'agriculture. Pendant les années 1980 ces émissions n'ont cessé d'augmenter jusqu'à atteindre les mêmes pourcentages que les grands secteurs d'émission de CO_2 . Et si ces autres grands secteurs ont émis de moins en moins depuis cette époque, le secteur du transport quant à lui a gardé son niveau d'émission stable pour devenir le secteur le plus émetteur de CO_2 en France.

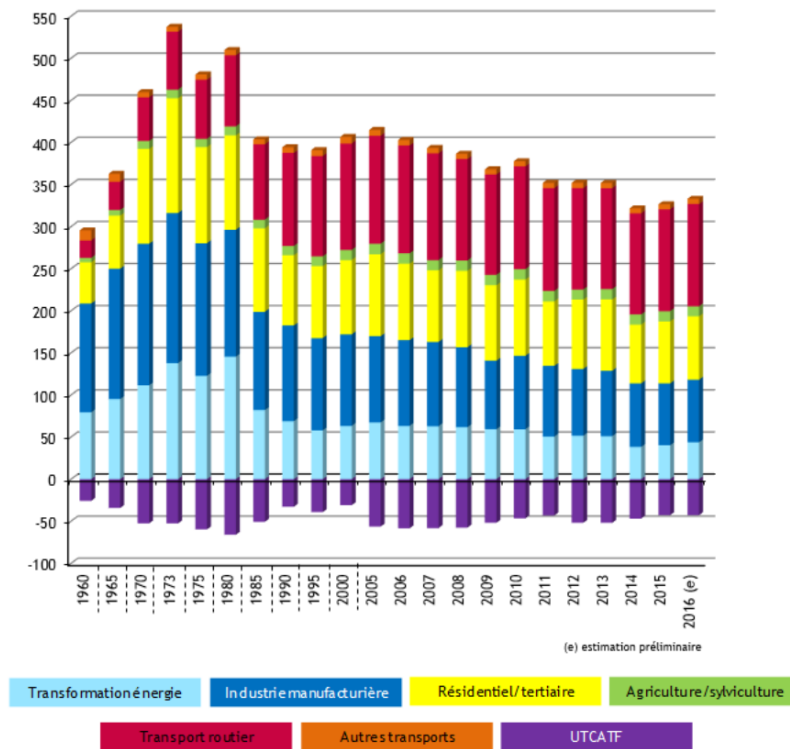


FIGURE 3 – Émissions atmosphérique de CO_2 en France métropolitaine entre 1960 et 2016, en Mt. *Source* : [2]

Le consensus international visant à réduire les émissions de CO_2 a donné plusieurs plans d'actions, en particulier dans le domaine du transport automobile. Au niveau européen, l'objectif fixé est une émission moyenne de $95gCO_2/km$ en 2020, puis entre 68 et $78gCO_2/km$ en 2025. La stratégie mise en oeuvre pour atteindre ces objectifs est une stratégie de pénalisation financière. Un dispositif *Bonus/Malus* à l'achat a été mis en place depuis 2007, il impose une amende (malus) aux véhicules avec un fort taux d'émission, et attribue des subventions (bonus) pour les véhicules présentant de faibles émissions de CO_2 . Ces politiques

appliquées aux conducteurs impactent la production des constructeurs automobiles et leurs flottes, d'autant plus qu'ils sont aussi directement taxés sur les sur-émissions du véhicule à la production. Les constructeurs automobiles se retrouvent alors, en plus de la question déontologique/écologique, devant un défi économique. La course aux technologies automobiles écologiques s'accroît alors depuis la fin des années 2000. Le taux de vente des véhicules Diesel, est passé de 78% en 2008 à 52% en 2016, et le nombre des ventes de véhicules électriques a augmenté de 26% entre 2015 et 2016. Généralement, le taux des ventes de véhicule de classe CO_2 A, B et C (émissions inférieures ou égales à $140gCO_2/km$) est passé de 40% en 2005 à 94% en 2016. La stratégie adoptée a alors mené à la réduction des émissions de CO_2 des véhicules d'une moyenne de $136gCO_2/km$ en 2012 à une moyenne de $118gCO_2/km$ en 2017 en Europe.

L'objectif fixé de $95gCO_2/km$ en 2020 n'est pas pour autant atteint. Il ne sera atteignable qu'en introduisant de plus en plus d'énergie électrique dans les véhicules. Évidemment, le mode de production d'électricité et son acheminement vers le réservoir a une trace CO_2 considérable. Ceci étant dit, en faisant abstraction de l'origine de l'énergie électrique, la voiture tout électrique avec une émission nulle de CO_2 sur la route est la solution idéale. Les politiques d'incitation financière et de sensibilisation, ont fait passer le nombre de ventes de véhicules électriques en France de moins de 1000 ventes en 2010, à plus de 21000 ventes en 2016. Néanmoins, ces ventes ne représentent aujourd'hui que 1.08% du total des ventes.




FIGURE 4 – Répartition des ventes de véhicules par types d'énergie en France en 2016. *Source : Evolution des marchés, caractéristiques environnementales et techniques, ADEME 2017*

Les véhicules électriques présentent l'avantage d'un véhicule sans émission de CO_2 sur la route. En plus du fait qu'aucune combustion d'énergie fossile n'est nécessaire, une chaîne de traction électrique permet une reproduction embarquée d'énergie électrique à travers le freinage régénératif. Cependant, ce type de véhicules présente deux inconvénients majeurs : le coût et l'autonomie. Sachant que les véhicules électriques garantissant une autonomie acceptable ont des batteries Lithium-ion, et vu la rareté du lithium, le prix de la batterie et donc du véhicule, est substantiellement élevé par rapport à un véhicule diesel ou essence classique. Le marché ne pourra s'élargir que si les prix sont plus abordables et que l'autonomie des

véhicules est plus adaptée à ses nécessités.

Le problème de l'autonomie du véhicule électrique reste quand même la cause principale de son utilisation limitée. Loin des propositions de *Testla Motors*, l'autonomie moyenne du véhicule électrique ne dépasse pas les 160km. A l'état actuel, les stations de recharge ne sont pas assez déployées car, d'une part les investisseurs ne voient pas de rentabilité dans le projet de stations de recharge, à cause du nombre réduit des conducteurs de véhicules électriques. D'autre part, tant qu'il n'y a pas assez de stations de recharge, le consommateur n'est pas convaincu par la voiture électrique.

Il paraît alors évident que le déploiement en masse des véhicules électriques n'est pas une solution viable à court terme, et que l'électrification partielle des véhicules présente un compromis raisonnable entre la dé-carbonisation du secteur du transport automobile et la garantie de l'autonomie des véhicules.

Le marché du véhicule hybride représente aujourd'hui 3% du marché des véhicules en France (Figure 4). Le marché de l'hybride connaît cependant une expansion considérable, grâce aux politiques visant à décarboner les transports. Entre 2016 et 2017, selon l'ACEA, la vente des véhicules hybrides en France a augmenté de 36%. Au niveau européen, ces ventes ont augmenté de 52%. La combinaison de l'énergie électrique à l'énergie fossile permet de s'inscrire dans la clause de réduction des émissions de CO_2 en ayant des garanties satisfaisantes en terme d'autonomie du véhicule, ce qui explique le succès relatif de cette technologie par rapport à la voiture électrique. Cependant le concept du véhicule hybride n'est pas tout à fait récent.

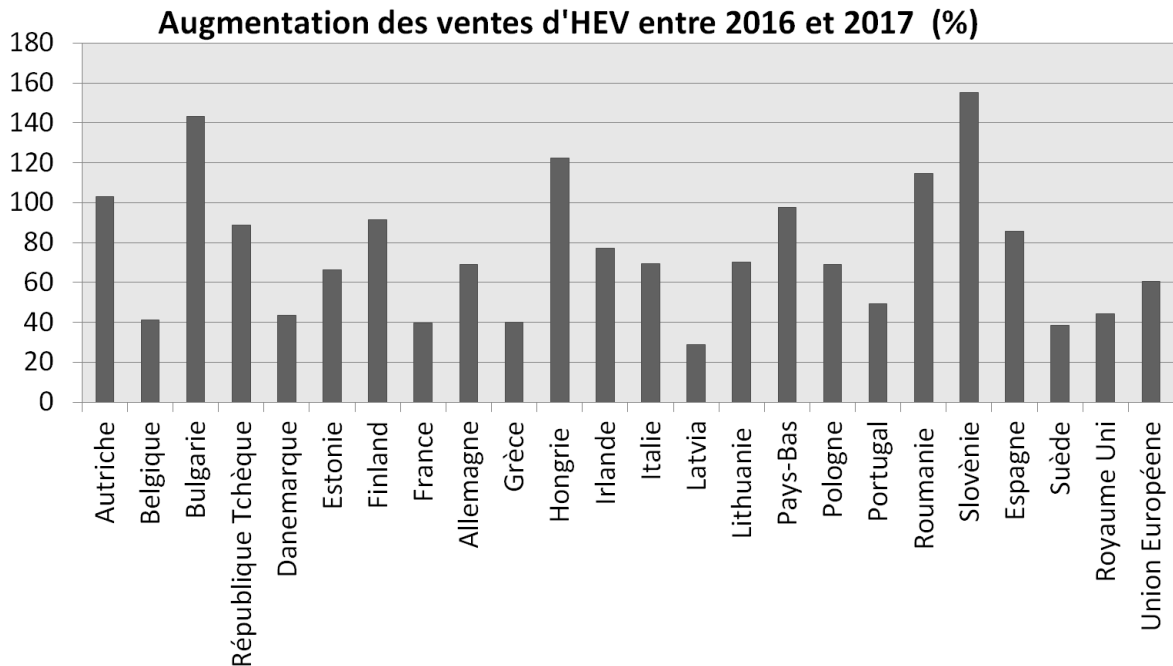


FIGURE 5 – Augmentation des ventes d'HEV entre 2016 et 2017. *Source : ACEA*

L'introduction d'une source d'énergie électrique à la chaîne de traction d'un véhicule a été réalisée pour la première fois en 1889 quand William H. Patton déposa le brevet pour une chaîne de traction hybride. Un moteur à essence entraînait un générateur pour charger une batterie au plomb qui alimentait le moteur électrique de traction [3]. Cette première invention ne sera néanmoins pas utilisée pour des véhicules de route, mais plutôt pour des rames de tramway.




FIGURE 6 – Schéma de l'architecture du *Woods Dual Power*, véhicule hybride construit en 1917. *Source* : [4]

Le premier véhicule hybride a été la Lohner-Porsche Mixte développée par Ferdinand Porsche en 1899. La première version de la *Mixte* a été la *Semper Vivus*, un véhicule complètement électrique avec deux moteurs électriques sur les roues avant. La batterie alimentant ces moteurs étant trop lourde pour être embarquée à des vitesses satisfaisantes, Ferdinand Porsche ajoutera un moteur à essence dans l'architecture. Le véhicule aura alors 4 moteurs électriques sur chacune des roues et le moteur à essence entraînera une dynamo pour alimenter la batterie plus légère. Ce véhicule constitue alors l'ancêtre des architectures série modernes. Trois cent Lohner-Porsche Mixte seront vendues jusqu'en 1906 [5]. En 1917 le constructeur de véhicules électriques *Woods Motor Vehicle* développe le *Woods Dual Power*. La chaîne de traction se composait d'un moteur à combustion de 4 cylindres avec un moteur électrique responsable de la traction et de la régénération d'énergie au freinage. Le véhicule utilisait une conduite complètement électrique pour les vitesses inférieures à 24km/h , et une conduite hybride au delà, pouvant aller jusqu'à 56km/h [4]. Cette prouesse technologique sera par contre un échec commercial. La difficulté à conduire le véhicule et son prix élevé par rapport à sa vitesse maximale feront que le véhicule ne sera pas assez vendu. L'hybridation électrique des véhicules n'est donc pas une idée récente. Ses premières réalisations remontent à plus d'un siècle. Du fait de l'hégémonie des moteurs à combustion interne, les technologies d'hybridation

des chaînes de traction vont évoluer lentement pendant le 20ème siècle, avec le développement de la technologie *Energy Regeneration Brake* par *American Motors Amitron* dans les années 60 [6], puis les travaux de Victor Wouk pendant les années 60 et 70 [7], jusqu'au premier véhicule hybride moderne commercialisé par *Audi* en 1989. Le premier véhicule hybride électrique déployé dans le monde est le *Toyota Prius*, commercialisé au Japon en 1997 puis en Europe et aux US à partir de 2000. Les technologies d'hybridation automobile deviennent de plus en plus variées. L'avènement des batteries au Lithium impactera les technologies d'hybridation. *Hyundai* lancera le premier véhicule hybride avec une batterie Lithium-polymère en 2009, le *Hyundai Elantra LPI Hybrid*, et le *Mercedes-Benz S400 BlueHybrid* sera le premier véhicule à embarquer une batterie Lithium-ion, en 2010.

Les développements et recherches réalisés durant tout le 20ème siècle sur les technologies hybrides nous mènent aujourd'hui à une liste de différents types d'hybridation [8] [9][10]. Les véhicules hybrides peuvent être classifiés de la manière suivante :

- Type de source d'énergie : L'énergie de traction du véhicule peut être issue d'une combustion de Diesel ou d'essence ou autre type de carburant. L'énergie électrique peut être stockée dans une batterie ou générée par une Pile à Combustible (PaC ou Fuel Cell) utilisant le vecteur hydrogène.
- Degré d'hybridation : La quantité de puissance électrique embarquée détermine différents types de véhicules hybrides. Les micro-hybrid qui sont des véhicules classiques avec quelques fonctionnalités hybrides, comme le Start/Stop. Le mild-hybrid est un véhicule hybride capable de traction hybride sur des courtes distances. Le full-hybrid qui est le véhicule hybride complet donnant la possibilité de conduite électrique, hybride ou thermique. Le Plug-in hybrid est un véhicule hybride disposant d'une prise de recharge, ce qui permet de faire des voyages complets en conduite électrique vidant l'élément de stockage en fin de parcours.
- Type d'architecture : Il y a 4 grands types d'architectures, l'architecture série (Figure 7-a), l'architecture parallèle (Figure 7-b), l'architecture série-parallèle (Figure 7-c) et l'architecture complexe (Figure 7-d). La façon d'imbriquer les deux sources d'énergie constitue la différence entre ces architectures. Dans une architecture série, qui a historiquement été la première technologie d'hybridation, la puissance est transmise du moteur thermique vers le moteur électrique qui est chargé exclusivement de la traction. Dans l'architecture parallèle les puissances des deux moteurs s'ajoutent sur les roues, tandis que leurs vitesses sont proportionnelles tant que les deux moteurs sont connectés aux roues. L'architecture série-parallèle constitue un mixte des deux précédentes architectures, où le véhicule peut avoir un fonctionnement parallèle ou série. Dans le fonctionnement série le moteur thermique alimente, à travers un générateur, la batterie, qui alimente le moteur électrique. Le mode parallèle consiste en la transmission directe du couple de chacun des moteurs aux roues. Dans l'architecture complexe, deux fonctionnements sont possibles : l'énergie peut être transmise du thermique vers l'électrique et vers les roues, ou de l'électrique vers le thermique. L'architecture complexe permet aussi un fonctionnement parallèle (Figure 7).

Ces différents types d'hybridation donnent différentes possibilités du point de vue échange

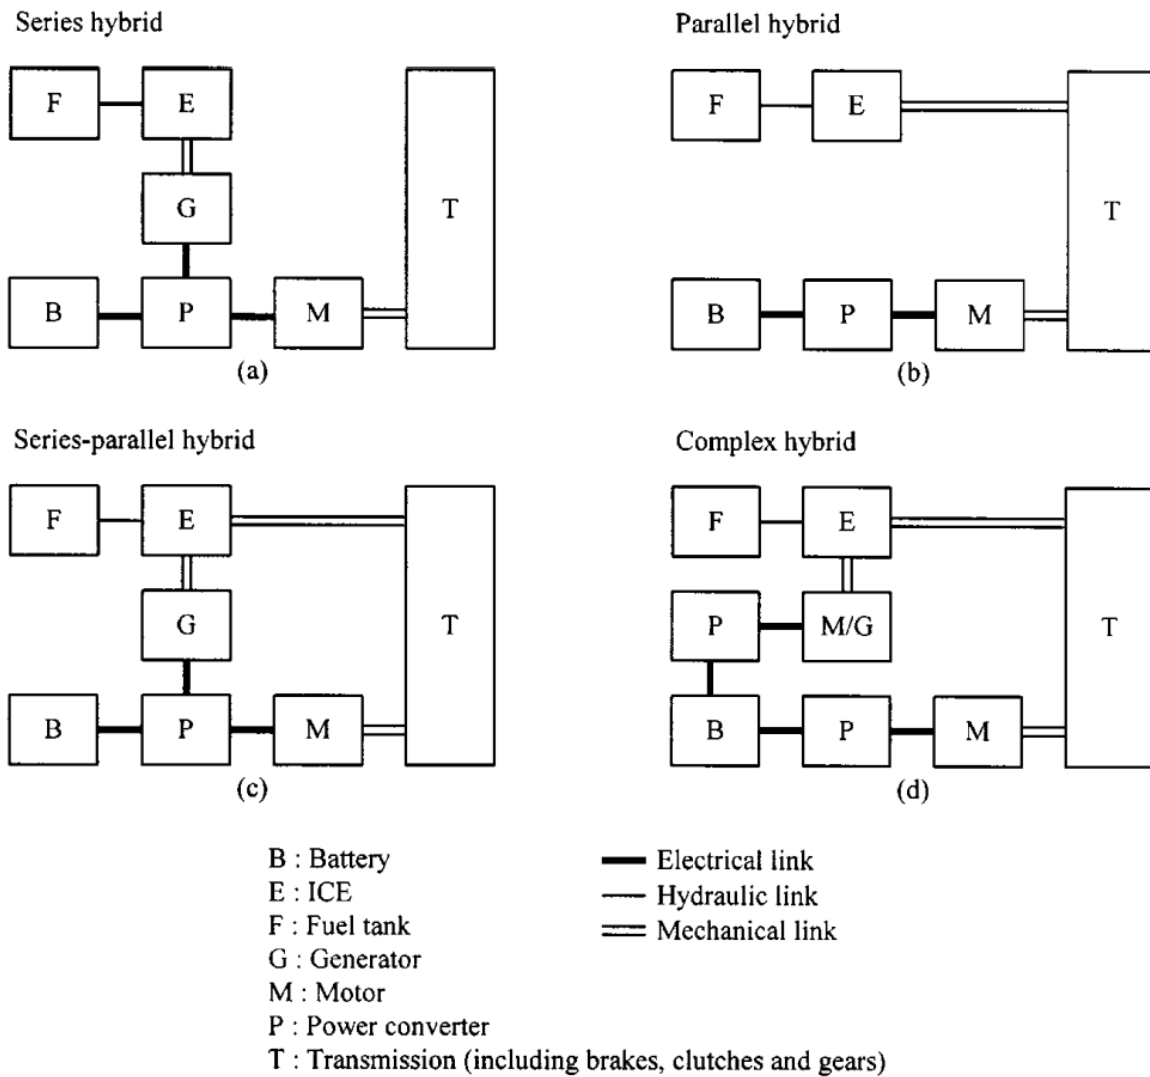


FIGURE 7 – Classification des architectures des véhicules hybrides électriques. *Source : [8]*

énergétique. La capacité de la batterie ou la puissance du moteur utilisé, par exemple, donnent plus ou moins de possibilités au véhicule hybride. L'architecture du véhicule et le dimensionnement de ses composants constitutifs étant fixés, sa performance énergétique reste encore améliorable et dépend d'un nouveau paramètre caractéristique des véhicules hybrides : la répartition de puissance entre les deux sources d'énergie du véhicule.

Le couplage de deux moteurs d'énergie dans un véhicule hybride crée un nouveau degré de liberté dans la chaîne de traction du véhicule. La proportion d'utilisation de chacun des moteurs est un nouveau nœud énergétique qui est complètement transparent du point de vue du conducteur, et qui doit être décidé en temps réel. Quand le conducteur d'un véhicule hybride électrique appuie sur l'accélérateur ou sur le frein, il demande une puissance positive ou négative à appliquer sur les roues. Cette puissance peut être fournie par le moteur électrique uniquement, ou par le moteur à combustion uniquement, ou par une combinaison des deux avec une certaine proportionnalité. Cette décision peut très bien être prise avec pour seul objectif d'assurer la puissance nécessaire à la conduite. Cependant, il ne faut pas oublier l'objectif principal de l'hybridation électrique, qui est la réduction de consommation des énergies fossiles et donc des émissions de CO_2 . La répartition de puissance sur les deux moteurs d'un véhicule hybride se fait alors dans le but de minimiser la consommation de carburant, tout en fournissant la puissance nécessaire à la conduite. Cette problématique qui est une fonctionnalité essentielle dans un véhicule hybride est appelée dans le milieu industriel *Energy Management*.

La question qui se pose est : Comment répartir l'énergie entre les deux moteurs d'un véhicule hybride le long d'un trajet, de façon à consommer le minimum de carburant possible, tout en gardant un certain niveau d'énergie électrique dans la batterie à la fin du trajet ? La quantité d'énergie électrique à garantir dans la batterie se décide différemment selon le type de véhicule hybride. Par exemple, pour un véhicule hybride *Plug-in* (avec prise de recharge) on peut se permettre de viser un niveau final d'énergie électrique bas, 10% par exemple, car on aura la possibilité de s'arrêter et de recharger sa batterie sur une borne. Par contre, dans un *Mild Hybrid* où l'on ne peut pas recharger la batterie sur une prise, on visera toujours un état de charge plus élevé que pour un *Plug-in*.

Par exemple, dans l'un des premiers véhicules hybrides de l'histoire, le *Woods Dual Power*, l'idée était de rouler en électrique en dessous de $24km/h$ puis en conduite hybride pour les vitesses supérieures. Ce fut l'une des premières stratégies d'*Energy Management* basée sur une règle heuristique. Une stratégie optimale dépend cependant des paramètres des composants de la chaîne de traction, essentiellement les rendements des moteurs et des transmissions.

Pour gérer cette énergie, certaines hypothèses peuvent être posées comme par exemple que la puissance électrique consommée par la machine électrique est proportionnelle au couple délivré (qu'il soit positif ou négatif), et qu'il n'y a pas de frottements aérodynamiques du véhicule. La première hypothèse signifie que l'on pourra récupérer par les couples négatifs exactement la même énergie électrique qui a été consommée par les couples positifs. La deuxième hypothèse implique qu'il faudra fournir autant d'énergie cinétique dans les phases d'accélération que dans les phases de décélération. Avec ces hypothèses, la solution optimale qui maintiendrait un même niveau de charge de la batterie est claire et simple. La traction électrique

entraînera le véhicule d'une position d'arrêt à une énergie cinétique maximale en consommant une certaine quantité d'énergie électrique. Cette même quantité sera récupérée par un freinage régénératif qui ramènera le véhicule de son énergie cinétique maximale, à une énergie cinétique nulle. La consommation de carburant est alors nulle. Evidemment, cet exemple est trop simplifié, et ne tient pas compte ni de la capacité de la batterie, ni des limites du moteur électrique. En effet, le moteur pourrait ne pas avoir assez de puissance pour atteindre l'énergie cinétique demandée par le conducteur, ou alors la batterie pourrait ne pas contenir assez d'énergie électrique. D'ailleurs, si cette configuration d'hypothèse était possible, le véhicule hybride n'aurait pas de sens car l'utilisation du moteur à combustion deviendrait inexistante et il deviendrait possible de rouler avec un véhicule électrique sans jamais le recharger.

Complexifions un tout petit peu le problème. Supposons maintenant que les frottements aérodynamiques fournissent la moitié de l'énergie nécessaire pour arrêter le véhicule. Cela voudrait dire que l'on ne pourra récupérer que la moitié de l'énergie cinétique d'accélération par freinage régénératif. Et donc pour retrouver une variation globale d'état de charge de la batterie nulle, il faudrait fournir la moitié de l'énergie de traction par le moteur à combustion. Cela étant dit, on ne résout pas encore le problème, car il faut encore répartir cet effort durant toute la phase d'accélération de manière à consommer le moins de carburant possible. La solution dépendra alors de la fonction qui relie la puissance mécanique à la masse de fuel consommée dans les cylindres du moteur à combustion, c'est-à-dire le modèle du véhicule lui-même. Le traitement de ce problème sans hypothèse caricaturale nécessiterait aussi la relation entre la puissance mécanique du moteur électrique et la variation de l'état de charge de la batterie associée.

La mention de ces deux cas d'hypothèses réductrices a pour but de souligner deux points. D'abord, la complexité du problème de l'*Energy Management*, même dans le cas d'une physique simplifiée. Le deuxième point, qui est primordial dans notre étude, est la nécessité d'une connaissance du profil de puissance utilisé sur la totalité du trajet, même dans des cas idéaux. En l'absence de cette connaissance, on n'a pas accès aux contraintes de notre problème. En effet, avant de pouvoir répartir de manière optimale la puissance sur les deux moteurs, il faudrait savoir quelle puissance on doit fournir. La nature embarquée de la fonctionnalité d'*Energy Management* implique, en d'autres termes, qu'il est nécessaire d'anticiper le futur. Cette constatation aurait pu dans le passé, constituer un frein considérable au développement de solutions rigoureusement optimales, mais qui donne encore lieu à des solutions heuristiques basées sur des règles fixes, au lieu de la recherche de l'optimum mathématique. Aujourd'hui, dans le contexte de l'*Internet of Thing* et de la connectivité des véhicules, acquérir une estimation de la puissance demandée lors du futur trajet est désormais possible. Ce qui peut donner lieu à des solutions d'*Energy Management* plus rigoureuses, permettant de meilleures économies en consommation de carburant et en émissions de CO_2 .

Continental Automotive et l'ADEME ont co-financé les travaux de cette thèse, dans le but d'explorer et de développer des méthodes de contrôle optimal appliquées en temps réel à la problématique de l'*Energy Management* dans le cadre d'une connectivité permettant l'anticipation du futur trajet, le but étant de réduire la consommation de carburant et des émissions de CO_2 . Les méthodes étudiées s'inscrivent dans la catégorie des méthodes à base de modélisations mathématiques et utilisant la théorie du contrôle optimal. Ces méthodes se

différencient des autres méthodes destinées à l'usage en temps-réel qui, à défaut de garantir un optimum mathématique, présentent des choix stables et prévisibles.

L'estimation des trajets futurs est essentielle pour un fonctionnement stable de la méthode étudiée. Ces estimations impliquent une vision probabiliste du problème car toutes les prévisions seront en réalité entachées d'incertitude. Il est cependant nécessaire dans un premier temps, d'analyser la méthode dans un cadre déterministe, sous l'hypothèse de fiabilité complète des prédictions, ce qui permettra de constater le potentiel de réduction des émissions de CO_2 , on pourra aussi dans ce cadre étudier la sensibilité du problème à une prédiction erronée.

Les incertitudes liées aux prédictions peuvent être vues comme des variables probabilistes dans les équations de contrôle optimal. Les modèles probabilistes utilisés, pour représenter notamment les demandes de puissance, permettront une optimisation viable sur des trajets plus ou moins longs. Cette analyse mènera vers la déduction d'horizons de prédiction robustes en fonction du modèle probabiliste utilisé. L'ensemble des méthodes et des algorithmes développés sera testé par simulation sur deux différentes architectures hybrides.

Le chapitre 1 présente l'état de l'art de la problématique de l'*Energy management*. Les méthodes existantes seront présentées et catégorisées. Dans le chapitre 2, les modèles des deux véhicules utilisés pour l'étude de notre méthode seront détaillés. Le problème d'*Energy management* sera alors formalisé en tant que problème de contrôle optimal déterministe puis probabiliste. Le chapitre 3 expose le développement de la méthode étudiée sous l'hypothèse de la fiabilité complète des prédictions de la connectivité. A travers des simulations sur différents trajets, la méthode sera évaluée et comparée à d'autres algorithmes. Ensuite, la modélisation des incertitudes des prédictions par des prédictions est développée dans le chapitre 4. La méthode probabiliste résultante est alors évaluée par simulation.

Etat de l'art

Sommaire

1.1 Méthodes à base de règles	13
1.1.1 Méthodes à logique de Boole et heuristiques	14
1.1.2 Méthodes à logique floue	15
1.2 Méthodes basées sur l'optimisation	16
1.2.1 Méthodes d'optimisation globale	17
1.2.2 Méthodes temps-réel	23
1.3 Contribution : Le Principe du Maximum de Pontryagin appliqué en temps-réel avec des prédictions probabilistes	26
1.3.1 Méthode d'optimisation	26
1.3.2 Approche prédictive	27

La présence de deux sources de puissance mécanique dans un véhicule hybride crée un degré de liberté permettant d'introduire une stratégie d'*Energy Management* pour répartir la puissance entre chacune d'elles. L'hybridation des véhicules a pour but de minimiser la consommation de carburant et pour atteindre ce but de manière optimale, la stratégie de répartition de puissance se doit de viser le même objectif. La caractéristique la plus importante dans un véhicule hybride est la possibilité de transformer l'énergie cinétique du véhicule en énergie électrique stockable dans la batterie, mais également de faire une somme des deux énergies fournissant l'énergie demandée/requise. La stratégie de gestion d'énergie a pour but de gérer ce flux bidirectionnel d'énergie électrique de manière aussi à utiliser les points de fonctionnement du moteur à combustion dans ses meilleurs rendements, c'est-à-dire ceux qui consomment le moins. La littérature est riche dans ce domaine et est en constante croissance du fait de l'intérêt accru des industriels, des contraintes gouvernementales et environnementales plus contraignantes faisant apparaître des problèmes et des contraintes qui sont encore verrous en recherche surtout pour l'implantation concrète en temps réel des solutions (Figure 1.1).

Les contraintes sur l'énergie électrique à maintenir dans la batterie diffèrent selon la connexion possible ou pas à une borne de recharge HEV ou PHEV. Un PHEV étant rechargeable sur une borne, on peut se permettre d'atteindre des niveaux de charge assez bas, alors que dans un HEV non rechargeable le but est de garder un niveau d'énergie assez élevé à la fin de chaque trajet. Cependant, cette différence résulte en une variation sur l'état de charge (SoC) qui est un paramètre du problème, et que nous pouvons laisser libre en le présentant




FIGURE 1.1 – Représentation graphique des publications par année d’articles sur les méthodes d’Energy Management. *Source* : [11]

comme un état de charge final objectif (SoCtarget) sans modifier le principe global que l’on peut traiter dans ce travail de manière générale.

La chaîne de traction d’un véhicule hybride est une composition de systèmes mécaniques, électriques et électro-chimiques. Le fonctionnement d’un tel système résulte en des circuits énergétiques difficilement modélisables finement. Le développement des fonctions d’*Energy Management* s’impose alors comme un sujet de recherche complexe. La finesse du modèle du véhicule utilisé mène à un problème d’optimisation difficile à manipuler en temps réel. Il est alors nécessaire de trouver une simplification du modèle qui représente un compromis entre la réalisation de l’optimisation en temps réel et la performance de la solution. A la complexité intrinsèque du problème causée par la nature physique hétérogène, s’ajoute l’aspect très variable des données d’entrée. En effet, les performances d’une stratégie d’*Energy Management* sont validées sur quelques trajets, alors qu’elle est destinée à s’appliquer sur une infinité de trajets. En conséquence de cette variabilité, les travaux de recherche sur le sujet ne convergent pas vers une méthode unique. Un grand nombre d’articles est publié chaque année, chacun présentant une approche différente, et montrant des baisses d’émission sur certains trajets avec un certain type de véhicules. Cette explosion dans l’activité de recherche sur l’*Energy Management* des véhicules hybrides est certainement due à la volonté des constructeurs automobiles de s’aligner sur les objectifs de réduction des gaz à effet de serre. Elle donne aujourd’hui une grande variété de méthodes qu’on peut répartir en deux grandes catégories : - Méthodes à base de règles et - Méthodes basées sur l’optimisation [12]. La Figure 1.2 résume la classification des méthodes présentées dans ce qui suit.

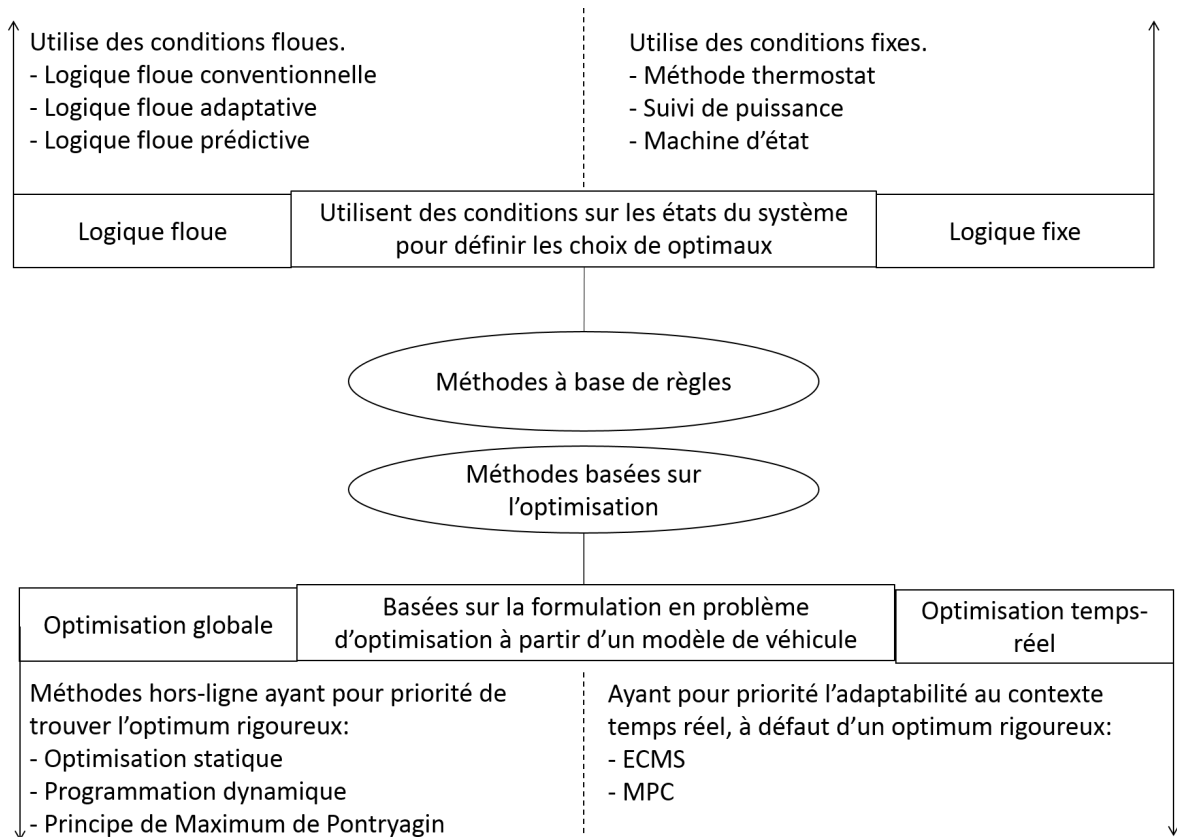


FIGURE 1.2 – Classification des méthodes de l'Energy management

1.1 Méthodes à base de règles

Les Méthodes dites à *base de règles* sont fondées sur des règles logiques souvent avec des conditions heuristiques plus ou moins complexes et qui affectent à chaque point de fonctionnement du système un comportement bien précis. Le plus grand avantage de cette catégorie de méthodes est qu'elles nécessitent un temps de calcul assez court pour un contexte temps réel. Les règles qui définissent ces stratégies sont déduites d'heuristiques basées sur l'expérience et l'intuition humaines. Par nature, ce type de méthodes n'a donc besoin d'aucune connaissance à priori du trajet. Les premiers véhicules hybrides ont été équipés de stratégies basées sur ce type de méthodes, notamment grâce à leur facilité d'implémentation (ex : si la puissance est faible et la batterie faible, alors utiliser la puissance électrique etc). Les méthodes à *base de règles* garantissent également un fonctionnement stable et invariable, ce qui est une caractéristique appréciable aujourd'hui dans le milieu automobile. En général, l'objectif des méthodes est la recherche des meilleurs points de fonctionnement possibles de l'ICE. La demande de puissance du conducteur est complétée par l'EMA selon le *SoC* de la batterie. Il existe deux *catégories* : Les méthodes à logique de Boole ou combinatoire et celles floue, Bayésienne ou pour lesquelles des méthodes d'optimisation sous forme d'apprentissage sont utilisées.

1.1.1 Méthodes à logique de Boole et heuristiques

Les méthodes à base de règles déterministes sont souvent des heuristiques basées sur l'analyse des cartographies des rendements ou des puissances de l'ICE, ce qui donne lieu à des règles intuitives dans des tables de décisions statiques. Plusieurs méthodes existent :

- Méthode du thermostat : C'est une stratégie basique où l'on maintient le *SoC* entre ses limites maximales et minimales prédéfinies, en utilisant l'ICE en ses meilleurs points de fonctionnement, jusqu'à ce que l'on en ait besoin pour recharger la batterie. Le fonctionnement de cette méthode requiert une batterie avec une grande performance pour pouvoir satisfaire toutes les demandes de puissance du conducteur [11]. Cette méthode présente un bas rendement global [13]. L'utilisation récurrente de l'ICE pour recharger la batterie en fait cependant une méthode qui peut être adaptée à certains véhicules à architecture série [14], [15].
- Méthode de suivi de puissance : Appelée aussi *Baseline strategy*, cette méthode utilise un algorithme plus développé avec plus de cas d'utilisation que le *Thermostat*. Le véhicule roule en mode purement électrique en dessous d'une certaine vitesse, et récupère de l'énergie électrique au freinage. L'ICE est utilisé comme source primaire de puissance, et l'EMA comme source complémentaire. L'ICE peut aussi être utilisé pour recharger la batterie en cas de décharge importante, ou il peut être éteint si la demande de puissance est inférieure à un seuil fonction du régime moteur [16]. Si cette stratégie, applicable aux architectures parallèles [17] et séries [18],[19], permet d'améliorer le rendement par rapport à la *méthode du thermostat*, elle reste une stratégie qui ne vise pas directement à minimiser la consommation ou les émissions de CO_2 [12]. Des méthodes basées sur le *suivi de puissance* ont cependant équipé les *Toyota Prius* et *Honda Insight*, premiers véhicules hybrides modernes commercialisés.
- Méthode de suivi de puissance modifiée : C'est une version améliorée de la *Baseline strategy* avec une approche adaptative. Au lieu de choisir à chaque instant le point de fonctionnement de l'ICE avec le plus haut rendement, cette méthode évalue les quantités de fuel et d'énergie électrique utilisées pour chaque point de fonctionnement candidat ce qui définit un facteur d'impact pour chaque point de fonctionnement. Le point de fonctionnement avec le plus petit facteur d'impact est choisi comme solution optimale [20],[21]. Cette méthode est une amélioration des méthodes précédentes dans la mesure où elle minimise directement un critère de consommation et d'émissions. C'est néanmoins une optimisation heuristique qui peut poser des problèmes dans le contexte temps-réel à cause de la charge de calcul qu'implique la méthode [12].
- Méthode par machine d'état : Cette méthode met en œuvre une modélisation séquentielle du problème. Les différents modes de fonctionnement de la chaîne de traction sont représentés par des états d'une machine d'états séquentiels dont les transitions sont dictées par les variations des différentes variables du véhicule. Si ce genre de méthode offre une supervision de contrôle robuste, elle ne garantit pas une optimisation

de critères de consommation de carburant ou d'émission de CO_2 [12], [22].

1.1.2 Méthodes à logique floue

Les méthodes à *base de règles floues* représentent une extension plus robuste des méthodes logiques à seuil fixe. La logique floue semble une solution idéale face à des problèmes mettant en jeu des systèmes multiphysique et non-linéaires comme les chaînes de traction hybrides électriques. En effet, la logique floue est moins sensible aux erreurs de mesure. En plus de la robustesse de ces méthodes, elles peuvent être facilement adaptables grâce à la définition des fonctions d'appartenance des règles floues.

- Logique floue conventionnelle : Quelques méthodes de logique floue ont été développées avec les mêmes principes que les méthodes *suivi de puissance*, où l'on exprime des conditions sur les vitesses de rotation et les demandes de puissance, en logique floue, en fonction desquelles le comportement est défini. Dans [23] et [24], les règles floues sont établies en fonction des paramètres mécaniques du système, alors que dans [25] et [26], les auteurs établissent des règles sur des estimations des couples qui maintiennent l'ICE sur des points de fonctionnement optimaux.
- Logique floue adaptative : Ces méthodes définissent des règles floues sur l'environnement du véhicule en plus de ses données physiques. En se basant sur l'expertise et les comportements constatés, dans [27] et [28] les auteurs ont établi des liens entre les caractéristiques du trajet et les coefficients d'un critère de répartition d'énergie. La situation du véhicule, par exemple la densité du trafic ou le type de route, détermine un critère différent à minimiser. D'autres travaux utilisent ces méthodes pour traiter le problème multicritère de minimisation de CO_2 et de polluants pour donner plus d'importance à un critère ou à un autre selon la situation du véhicule [29].
- logique floue prédictive : Avec la disponibilité des systèmes de géo-localisation, des méthodes à logique floue visant à minimiser la consommation de carburant utilisent des prédictions. Des règles floues sur les conditions de conduite futures définissent la solution de répartition d'énergie, [30], [29]. Par exemple, en détectant que le véhicule passera d'une route extra-urbaine à une route urbaine avec un trafic élevé, en rechargeant la batterie en vue de la future utilisation de l'énergie électrique à basse vitesse. Afin d'utiliser cette possible prédiction du trajet, certains auteurs établissent les coefficients des fonctions d'appartenance par des méthodes de supervision ou d'apprentissage, ces méthodes donnent des solutions spécifiques au trajet et sont peu robustes sur d'autres.

Les stratégies à *base de règles* sont des stratégies temps-réel constituées d'un ensemble de règles issues de l'expertise des ingénieurs automobile étayées par des expérimentations diverses. Ce sont néanmoins des méthodes heuristiques très dépendantes des caractéristiques de chaque véhicule. Ces méthodes manquent d'analyse mathématique théorique, les seuils et les conditions sont alors difficiles à valider de manière générique. Des calibrations de ces

méthodes doivent être effectuées sur chaque type de véhicule, et pour chaque type de trajet et ce, sans aucune garantie d'optimalité. Plusieurs travaux ont essayé de combler le manque d'analyse mathématique des méthodes à *base de règles*, soit en calibrant ces méthodes par des résultats de méthodes basées sur l'optimisation et le contrôle optimale[31][32], soit en combinant les règles heuristiques à des méthodes basées sur l'optimisation [33][34].

Le problème d'*Energy Manangement* est un problème d'optimisation par nature. Il en découle évidemment que la recherche de solution passe par une résolution d'une formalisation et d'une formulation du problème d'optimisation. Si les méthodes à *base de règles* ont pu être adoptées grâce à leur facilité d'implémentation par rapport aux méthodes basées sur l'optimisation qui demandent un effort de modélisation et de résolution théoriques, elles ne vérifient aucun critère d'optimalité théorique et se voient de nos jours dépassées en termes de qualité des solutions par les méthodes à base d'optimisation.

1.2 Méthodes basées sur l'optimisation

Les méthodes basées sur l'optimisation s'attaquent au problème de front. La première étape est la modélisation du système, en utilisant des formules analytiques ou des données expérimentales décrivant la physique des composants de la chaîne de traction. La deuxième étape est la formulation du problème d'optimisation ou de contrôle optimal à partir du modèle établi. Enfin, il reste à trouver une solution à ce problème. La modélisation de ce type de problématique mène généralement vers une formulation d'un problème non-linéaire, ce qui fait que la résolution analytique pouvant donner une solution implémentable en une ligne de calcul est inaccessible. Malgré les différences dans la modélisation qu'il peut y avoir, la différence principale réside dans les méthodes de résolution adoptées.

En plus des difficultés de modélisation et de résolution des méthodes basées sur l'optimisation, la recherche rigoureuse de solution impose la connaissance a priori du futur trajet. Cette nécessité a sans doute été le frein principal de cette catégorie de méthodes. L'autre différence principale entre les différentes méthodes est alors la manière d'acquérir ou d'estimer la connaissance sur le futur trajet. Si les méthodes dédiées à la recherche d'optimum global avec des algorithmes hors ligne ne sont pas concernées par cette question, le contexte temps-réel de l'*Energy Management* embarqué impose aux méthodes temps-réel basées sur l'optimisation d'y répondre avec une solution robuste et fiable.

Il existe deux types d'approche basées sur l'optimisation. La première n'a pas pour priorité de respecter les contraintes d'une implémentation en temps-réel, et se donne comme objectif principal de trouver l'optimum global de répartition de puissance sur un parcours bien défini. Elle est usuellement désignée dans la littérature par : *méthodes d'optimisation globale*. La deuxième est dans la catégorie des *méthodes temps-réel*, qui sont des méthodes qui visent une optimisation embarquée sans obligatoirement se focaliser sur le caractère global de l'optimum. Ces méthodes adaptent l'approche basée sur l'optimisation au contexte temps-réel, et qui reste en lien avec la problématique de la prédiction du futur trajet.

1.2.1 Méthodes d'optimisation globale

Les méthodes d'optimisation globale s'appuient sur une modélisation et résolution mathématique du problème d'optimisation sous-jacent. Le nom de cette catégorie peut porter à confusion car ces méthodes n'utilisent pas toutes des méthodes d'optimisation globale. L'adjectif "global" fait allusion à la prise en compte du problème en sa globalité, sur toute la durée du trajet, par opposition aux méthodes à bases de règles qui ne traitent que du "cas par cas" à chaque instant. Deux approches existent, selon la modélisation du problème. Une description de la dynamique du système mène à des problèmes de contrôle optimal, on parle alors d'optimisation dynamique. Une discrétisation du problème peut transformer le problème en un problème d'optimisation statique.

1.2.1.1 Optimisation statique

La modélisation du problème en problème d'optimisation statique se fait en discrétisant les équations dynamiques du système. Ce qui mène vers un problème d'optimisation classique avec autant de variables de décision que d'échantillons temporels. Il en découle une problématique liée à ce genre de méthode : un échantillonnage assez fin augmente considérablement la dimension du problème et donc la difficulté à le résoudre. Ce type de méthode peut être partagé en deux catégories. Dans le cas où l'on dispose des équations analytiques des paramètres du système, on peut avoir accès aux dérivées du problème, et l'on peut donc utiliser des méthodes d'optimisation locale de descente. Par exemple, une résolution avec optimisation quadratique SQP a été appliquée dans [35]. Ces méthodes convergent vers des optima locaux. De plus, il faut que la modélisation du problème vérifie toutes les conditions de continuité et de dérivabilité. De ce fait, cette catégorie de méthodes n'est pas très utilisée dans les stratégies d'*Energy Management*.

L'autre catégorie est celle des méthodes d'optimisation sans dérivée, soit par manque d'équations analytiques décrivant la physique du système, soit pour éviter les inconvénients des méthodes utilisant les dérivées (discontinuité, difficultés de calcul...). Une multitude de méthodes ont été utilisées [13]. Parmi ces méthodes, on peut citer la méthode du simplexe non-linéaire de Nelder Mead [36], le simplexe modifié [37] et la méthode DIRECT¹ [38]. Les méthodes d'optimisation statiques les plus populaires ont cependant été les méthodes de recherche d'optimisation combinatoire et/ou stochastique comme les "algorithmes génétiques" [39], la méthode du recuit simulé [40], les "essais particuliers" [41],[42]. Les méthodes de recherche stochastique ont l'avantage de pouvoir trouver l'optimum global. Elles ont alors été jugées plus adaptées au problème de l'*Energy Management* que les méthodes d'optimisation à dérivée, mais selon la taille des populations et des fonctions de coût à évaluer, des temps de calculs importants sont requis.

Ces méthodes peuvent trouver l'optimum global, mais ne le garantissent pas de part leur nature stochastique ou locale. Les méthodes sans dérivés nécessitent une importante

1. DIvided-RECTangles [38]

charge de calculs vu que ce sont des méthodes avec exploration de tout l'espace des solutions. En ajoutant à cela la nécessité d'une discrétisation assez fine du problème garantissant une représentativité satisfaisante de la dynamique du problème, l'effort calculatoire de ce type de méthodes n'est pas adapté à une implémentation en temps réel. Et malgré le fait que quelques-unes de ces méthodes peuvent donner un optimum global sur un trajet, les méthodes d'optimisation dynamiques peuvent mieux garantir cet optimum.

1.2.1.2 Optimisation dynamique

Une description rigoureuse de la physique du problème de l'*Energy Management* mène à une modélisation en problème de contrôle optimal. Les variables d'état du véhicule doivent être contrôlées entre un point initial et un point final, tout en minimisant un critère donné, qui correspond à la consommation de l'ICE dans ce travail. Le contrôle optimal peut considérer des problèmes à plusieurs états. Généralement, l'*Energy management* est modélisé en un problème à 1 état. Pour simplifier, nous présentons ici un problème de contrôle optimal avec un seul état :

$$\begin{aligned}
 \min_u \quad & J = \int_0^T f(x(t), u(t)) \cdot dt \\
 \text{sous contraintes :} \quad & \dot{x} = g(x(t), u(t)) \\
 & x(T) = x_f \\
 & x(0) = x_0 \\
 & u_{min} < u(t) < u_{max} \\
 & x_{min} < x(t) < x_{max}
 \end{aligned} \tag{1.1}$$

où f est la fonction décrivant la dynamique de l'état x , x_f l'état final souhaité et x_0 l'état initial. f est la fonction critère dont l'intégrale sur la durée T est minimisée. u est le contrôle ou commande. Concrètement, un problème de contrôle optimal a pour objectif de calculer la manière optimale de mener l'état x de sa valeur initiale x_0 à la valeur finale x_f , la solution optimale étant le contrôle qui minimise le critère intégral J . Deux principales méthodes de résolution de problèmes de contrôle optimal existent :

Programmation Dynamique La DP (Programmation Dynamique) a été utilisée pour la première fois par Richard Bellman en 1940 [43] pour trouver la succession optimale de commandes pour un problème donné. La programmation dynamique est un procédé algorithmique issue d'équations mathématiques garantissant l'optimalité pour des problèmes de commande optimale. Les états du système étudié sont discrétisés, et le problème est temporellement échantillonné en micro-problèmes qui sont successivement optimisés [44]. Elle a la spécificité de pouvoir garantir l'optimum global d'un problème de contrôle optimal, ou plus précisément de sa version discrétisée. Cependant, la méthode nécessite une puissance de calculs incompatible avec une implémentation temps-réel. Dans un problème de programmation dynamique,

le problème est discrétisé, et le critère à minimiser peut alors s'exprimer par :

$$C = \sum_{k=0}^{N-1} f(x_k, u_k) \quad (1.2)$$

où f est la fonction coût, x_k et u_x sont respectivement l'état du système et sa commande à l'instant k . La programmation dynamique introduit un critère intermédiaire qu'on appelle *cost to-go*, et qui est associé à un état x_k à un instant k . Ce critère définit le coût optimal entre l'état actuel x_k à l'instant k et l'état final visé x_N à l'instant N . Il s'écrit comme la somme du coût menant le système vers l'état suivant à partir de l'état présent, et le critère *cost to-go* à l'état suivant.

$$J_k(x_k) = \min_{u_k} (f(x_k, u_k) + J_{k+1}(x_{k+1})) \quad (1.3)$$

A l'instant final le critère *cost to-go* est nul, puisqu'on est déjà à l'état souhaité à l'instant souhaité $J_N(x_N) = 0$. La programmation dynamique propose donc de partir de l'instant final N à l'état x_N et de calculer pour chacun des états du système possible le coût pour y arriver en partant de l'instant précédent, ce qui définit le critère *cost to-go* à cette instant :

$$J_{N-1}(x_{N-1}) = \min_{u_{N-1}} (f(x_{N-1}, u_{N-1}) + J_N(x_N))$$

En ayant défini $J_{N-1}(x_{N-1})$, on peut calculer $J_{N-2}(x_{N-2})$... et ainsi de suite jusqu'à atteindre :

$$J_0(x_0) = \min_{u_0} (f(x_0, u_0) + J_1(x_1))$$

qui est le critère *cost to-go* à l'instant initial qui représente finalement la trajectoire optimale entre l'état initial et l'état final.

On peut retrouver le critère initial à minimiser (1.5) en remplaçant toutes les expressions *cost to-go* du procédé itératif à tous les instants les unes dans les autres :

$$\min_{u_N} \{f(x_N, u_N) + \min_{u_{N-1}} \{f(x_{N-1}, u_{N-1}) + \dots + \min_{u_0} \{f(x_0, u_0)\} \dots\}\} \quad (1.4)$$

Dans l'expression (1.4), on peut sortir tous les termes de minimisation à gauche de l'équation et chacune des variables de décisions u_k se trouve à droite. On retrouve alors :

$$\min_{u_N} \min_{u_{N-1}} \dots \min_{u_0} \sum_{k=0}^{N-1} f(x_k, u_k) = \min_{(u_0, \dots, u_{N-1}, u_N)} \sum_{k=0}^{N-1} f(x_k, u_k) = \min_{(u_0, \dots, u_{N-1}, u_N)} C \quad (1.5)$$

ce qui correspond au critère que l'on cherche à minimiser.

Grâce à la discrétisation de l'espace d'état du système en plus de l'échantillonnage temporel, la méthode de programmation dynamique peut assurer l'exploration de toute la zone des solutions admissibles et trouver la solution globale. D'une part, la qualité de la solution dépend de la finesse de la discrétisation. Cependant, le nombre de cas à explorer et donc la

charge de calculs augmente avec une discrétisation fine. Ce nombre de calculs augmente alors d'autant plus avec les problèmes multidimensionnels.

La programmation dynamique a été la première approche d'optimisation globale déterministe pour l'*Energy Management* [45]. La fonction f représente alors la fonction de consommation de carburant. L'état x le *SoC* et la commande u représente la répartition de couple. La perturbation v représente alors la demande de couple par le conducteur et bien que cette dernière n'intervienne pas dans le critère à minimiser, elle intervient dans la dynamique du système. Il est surtout à noter que les stratégies basées sur la programmation dynamique considèrent cette perturbation, ou la demande de puissance connue. C'est-à-dire que ce sont des méthodes qui se basent sur une connaissance à priori du trajet. En conséquence, ces méthodes n'ont pas eu pour objectif une implémentation en temps réel. En effet, pour un seul trajet, un algorithme de programmation dynamique prend un temps conséquent pour calculer l'optimum global correspondant à l'énergie minimale consommée par le véhicule [46]. La programmation dynamique a cependant été utilisée pour extraire des règles utilisables par les stratégies à base de règles, ou pour calibrer des paramètres d'autres types de méthode [47], [48]. La méthode a aussi été appliquée pour différents types d'architecture visant à analyser le potentiel d'une optimisation globale, ou en combinant avec d'autres types de méthode [49], [50]. Par ailleurs, l'un des objectifs de l'utilisation de la programmation dynamique est l'évaluation de performances d'autres méthodes [51].

Principe du Maximum de Pontryagin La théorie mathématique du contrôle optimal développée par Lev Pontryagin dans les années 50 a mené à un théorème décrivant les conditions nécessaires d'optimalité d'un problème de contrôle optimal : Le Principe du Maximum de Pontryagin (PMP) [52]. Ce théorème donne lieu à une méthode qui permet analytiquement de décrire la solution optimale.

Contrairement à la programmation dynamique, le PMP permet de considérer le problème de contrôle sans avoir besoin de le discrétiser. Rappelons le critère à minimiser et l'équation dynamique de l'état :

$$C = \int_0^T f(x(t), u(t)) dt \quad (1.6)$$

$$\dot{x} = g(x(t), u(t)) \quad (1.7)$$

Dans le cadre du théorème du PMP, deux grandeurs sont définies. L'Hamiltonien H définit par (1.8) et l'état adjoint λ définit par l'équation différentielle (1.9).

$$H(u(t), x(t), \lambda(t)) = f(x(t), u(t), v(t)) + \lambda(t).g(x(t), u(t), v(t)) \quad (1.8)$$

$$\frac{\partial H}{\partial x} = -\dot{\lambda} \quad (1.9)$$

Le PMP affirme que tout optimum local du problème de contrôle est obtenu en minimisant

à chaque instant l'Hamiltonien du problème :

$$\forall t \in [0, T] \quad u^{opt}(t) = \arg \min_u (H(u(t), x(t), \lambda(t))) \quad (1.10)$$

La résolution du problème de contrôle optimal se ramène à la résolution d'un système d'équations différentielles donné par les équations (1.9), (1.8) et (1.7), avec des conditions initiales et terminales sur l'état. Ce système peut théoriquement être résolu analytiquement, mais il est généralement résolu par des méthodes numériques à cause de la non-linéarité des problèmes qui rend la résolution analytique inaccessible.

L'Hamiltonien peut être considéré comme un critère instantané, dont la minimisation à chaque instant, selon le théorème du PMP, garantie de minimiser le critère intégral (1.6). Il faut alors être capable de calculer l'Hamiltonien à chaque instant, ce qui implique le calcul de l'état adjoint λ . L'état adjoint est défini par l'équation différentielle (1.9).

Pour la méthode indirecte de tirs, la détermination de la condition initiale pour l'équation (1.9) est primordiale pour résoudre le problème de contrôle optimal. En effet, cette initialisation du co-état va permettre de calculer l'état final $x(T)$ et il ne restera à vérifier que la condition terminale sur l'état. En partant de l'équation :

$$x(T) = x(0) + \int_0^T f(x(t), u(t)) dt,$$

et en appliquant la condition d'optimalité du PMP (équation (1.10)), l'état final correspondant est :

$$x(T) = x(0) + \int_0^T f \left(x(t), \arg \min_u (H(u(t), x(t), \lambda(t))) \right) dt.$$

Nous pouvons bien voir sur cette équation que l'état final dépend de $\lambda(t)$ et donc à fortiori de sa valeur initiale $\lambda(0)$. Pour garantir la contrainte sur l'état final, l'état adjoint initial doit être solution du système d'équations (1.10) (1.9) et (1.8). Cependant, la résolution de ce système impose l'intégration de l'équation du système et de l'équation différentielle définissant l'état adjoint. Ces intégrations sont généralement, pour les problèmes de contrôle optimal, impossible à réaliser analytiquement notamment à cause de la non-linéarité de ces systèmes. Afin de calculer l'initialisation de l'état adjoint qui satisfait l'état de charge final, l'intégration est alors réalisée numériquement par un algorithme qui retourne $x(T)$ à partir d'une valeur donnée pour $\lambda(0)$, comme par exemple, une méthode d'Euler ou de Runge-Kutta. Nous définissons ainsi une fonction tir, qui à partir de $\lambda(0)$ calculera $x(T)$, et qui sera notée $Tir(\lambda(0)) = x(T)$. La recherche de l'initialisation de l'état adjoint est alors équivalente à la recherche de zéros de la fonction $Tir(\lambda(0)) - x_f$. Ce procédé de résolution est appelé la méthode indirecte de tirs. La détermination de $\lambda(0)$ permet de résoudre le système d'équations défini par les équations du PMP en vérifiant les contraintes sur l'état final. Le problème de contrôle optimal est ainsi complètement résolu.

La grande difficulté dans l'application du PMP à la problématique de l'*Energy management* est l'initialisation de l'état adjoint, c'est à dire la détermination de $\lambda(0)$ qui permet d'obtenir le contrôle optimal. L'état contrôlé étant l'état de charge de la batterie, il est néces-

saire de maîtriser l'initialisation de λ pour éviter des surcharges ou décharges indésirables de la batterie. La complexité et non-linéarité des équations modélisant la batterie et la chaîne de traction empêche l'intégration de l'équation du système analytiquement. Mais surtout, l'intégration nécessite la connaissance à priori du trajet futur.

Le PMP a cependant d'abord été appliqué à l'*Energy management* pour calculer la solution optimale avec une connaissance à priori du trajet [53]. L'Hamiltonien, qui est un critère instantané à minimiser (1.8), permet néanmoins une structure facile à implémenter en temps-réel, en déterminant $\lambda(0)$ de manière rapide et heuristique mais non rigoureuse. Ainsi, des travaux ont présentés des méthodes qui utilisent la minimisation de l'Hamiltonien sans pour autant chercher l'initialisation rigoureuse du co-état. Dans plusieurs travaux visant l'implémentation en temps réel, l'erreur entre le *SoC* mesuré et une trajectoire de *SoC* pré-déterminée est corrigée avec un correcteur proportionnel [54], proportionnel intégral [55], ou proportionnel intégral dérivé [56]. Encore une fois, ces méthodes supposent une connaissance de la trajectoire optimale de *SoC* à l'avance, et donc du trajet à priori. La nécessité d'une connaissance à priori du trajet a poussé vers le développement de méthodes qui anticipent à l'aide de prédictions sur le trajet futur ou au moins de classification en type de trajets. Par exemple, dans [57] l'auteur propose une méthode basée sur la reconnaissance de types de trajet, liant à chaque type de trajet une initialisation du co-état initial fixée. Dans [58], il est proposé une méthode qui allie les deux approches précédentes, l'utilisation de co-états initiaux pré-fixés, avec une correction de la trajectoire de l'état de charge. D'autres méthodes utilisent la connectivité du véhicule pour estimer des caractéristiques sur le futur trajet, ce qui leur permet d'en déduire une initialisation du co-état. Dans [59], l'auteur utilise les informations GPS pour prédire la puissance moyenne lors du trajet, ainsi que le potentiel de décharge de la batterie pour estimer une initialisation optimale du co-état. Dans [60], le temps du trajet ainsi que le potentiel d'énergie électrique récupérable sont déduits des informations GPS, pour ensuite estimer une initialisation du co-état. Ces méthodes nécessitent donc des calculs hors ligne avant le départ (ou en tâche de fond, sur plusieurs secondes ce qui reste admissible en embarqué).

L'utilisation du PMP pour résoudre le problème de l'*Energy Management* s'avère être une solution très performante. D'une part, théoriquement c'est une approche mathématique adaptée à la modélisation continue du problème et d'autre part parce que les performances obtenues par PMP peuvent converger vers l'optimum global qu'on peut trouver par programmation dynamique [60]. Et si la programmation dynamique requiert un temps de calcul inadapté au contexte temps réel, le PMP peut être quant à lui embarqué.

Pour ces deux raisons, cette thèse s'intéressera principalement à l'étude d'une méthode à base d'optimisation PMP, embarquable, pour des calculs en ligne, tenant compte des incertitudes sur les trajets. En effet, bien que des travaux aient montré l'efficacité et le potentiel de cette approche, plusieurs questions restent à traiter, notamment l'analyse de la performance du PMP et l'impact de l'incertitude des prédictions sur l'optimalité. Une critique plus détaillée par rapport à l'état de l'art ci-dessus sera abordée dans 1.3. La résolution du problème de l'*Energy Management* par le PMP traitée dans cette thèse y sera présentée.

1.2.2 Méthodes temps-réel

Les stratégies d'*Energy Management* basées sur l'optimisation globale ne sont en général pas adaptées à l'utilisation en temps réel, à cause de la charge de calculs importante qu'elles peuvent exiger. Les stratégies dites temps-réel donnent la priorité à l'aspect embarquable de la solution au dépend de l'optimalité globale. Ainsi ce type de méthode définit un coût instantané de manière à maintenir un équilibre entre consommation de carburant et consommation d'énergie électrique. Puisque ces méthodes sont indépendantes du trajet futur, elles sont relativement faciles à implémenter. Deux types de méthodes temps-réel sont incontournables dans la littérature : l'ECMS (Equivalent Consumption Minimization Strategy), et les méthodes MPC (Model Predictive Control).

1.2.2.1 Equivalent Consumption Minimization Strategy

L'idée derrière la stratégie ECMS est de transformer le critère intégral sur toute la durée en un critère instantané. Ce critère local est alors la somme de la consommation de carburant et de la consommation électrique convertie en son équivalent de carburant. L'esprit de la méthode est basée sur la résolution du problème de contrôle optimal en utilisant le PMP. La transformation de puissance électrique consommée en carburant équivalent se fait avec un facteur d'équivalence multiplicatif, qui correspond au co-état λ introduit dans le PMP (1.8) [61]. La méthode a été introduite pour la première fois dans [62]. L'utilisation d'une approximation du PMP comme méthode de résolution dans cette stratégie permet une implémentation temps-réel [63]. Néanmoins, la méthode n'apporte pas en soi une plus value par rapport à la résolution de l'initialisation du co-état du PMP. Si la spécificité de l'ECMS est ce "regard qualitatif" sur les équations du PMP, la calibration du facteur d'équivalence, qui correspond à l'initialisation de l'état adjoint du PMP, reste le problème principal. Les approches ECMS se différencient alors par la façon de calibrer le facteur d'équivalence.

Dans plusieurs travaux, le facteur d'équivalence est considéré constant et pré-calibré avec différentes méthodes. Dans [64] par exemple, le facteur d'équivalence est calculé en moyennant les rendements de l'énergie du carburant et de l'énergie électrique. D'autres travaux utilisent des méthodes d'optimisation globale comme la Programmation Dynamique [65], ou des algorithmes d'optimisation stochastiques [66], [67], [68] et [69] pour la pré-calibration du facteur d'équivalence de l'ECMS. Le calcul du facteur d'équivalence constant sur tout le trajet reste cependant très dépendant du trajet futur, qui doit être prédit à l'avance.

D'autres approches basées sur l'ECMS proposent une adaptation en ligne du facteur d'équivalence. En utilisant des correcteurs proportionnel [70], proportionnel intégral [71], [72], [73] ou un correcteur non-linéaire [74], le facteur d'équivalence est mis à jour pour réguler le *SoC* de façon à suivre une trajectoire précalculée avec une méthode d'optimisation globale. Encore une fois ces méthodes restent dépendantes d'une prédiction du trajet futur pour pouvoir déterminer la trajectoire de *SoC* sur laquelle se caler.

En vue de pouvoir s'affranchir de la problématique de prédiction du trajet futur dans les

méthodes ECMS, différents travaux ont créé des cartographies de données fixes donnant un facteur d'équivalence en fonction des états instantanés et futurs du système, comme le *SoC* ou la vitesse du véhicule. Les moyens de connectivité sont utilisés comme outil de prédiction [75],[76]. Ces méthodes, appelées T-ECMS (Telemetry-ECMS) ou A-ECMS(Adaptive-ECMS), embarquent des données pré-calculées pour différentes situations que les outils de connectivité peuvent détecter. Néanmoins, il est difficile, voire impossible, de dénombrer toutes les situations possibles. L'autre grand inconvénient de ces méthodes, est l'incertitude des prédictions issues de la connectivité et d'estimer son impact sur l'optimalité de la solution.

L'ECMS est une forme réduite du PMP. Ce dernier donne un critère instantané à minimiser, que l'ECMS interprète comme un critère mettant en balance l'énergie du carburant avec son équivalent en énergie électrique, à juste titre. La grande différence avec l'utilisation rigoureuse du PMP réside dans la considération du co-état, ou facteur d'équivalence. L'ECMS maintient son approche qualitative dans la recherche du facteur d'équivalence, sans respecter l'équation (1.8) qui donne les variations de ce facteur pour une solution rigoureusement optimale. Si les méthodes ECMS ont l'avantage d'être plus embarquables, elles ne donnent alors pas de garantie d'optimalité bien qu'elles soient basées sur le PMP.

1.2.2.2 Model-Predictive Control

Comme vu précédemment, l'*Energy Management* nécessite donc incontestablement des prédictions sur le trajet futur. Cet aspect peut être assuré par le principe du Model-Predictive Control. Le MPC est une stratégie de contrôle basée sur la prédiction, et a été utilisée dans différents domaines de l'industrie [77].

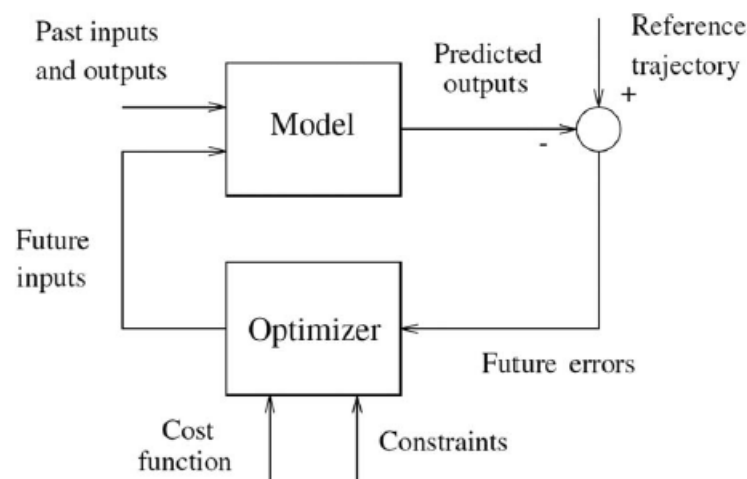


FIGURE 1.3 – Schéma bloc général d'un Model-Predictive Control. *Source : [77]*

La Figure 1.3 illustre le schéma-bloc du principe MPC. Il est composé d'un modèle de prédiction, qui sert à calculer les sorties du système sur un horizon de prédiction de N périodes d'échantillonnage. Cette prédiction est alors comparée à la trajectoire de référence pour en

déduire l'erreur sur l'horizon de prédiction. Le deuxième composant du schéma MPC est le contrôleur, qui calcule à partir de cette erreur la commande du système qui sera appliquée sur l'horizon de contrôle de durée $k < N$ périodes d'échantillonnage. L'horizon de prédiction glisse alors sur k périodes d'échantillonnage, et le processus est itéré (Figure 1.4). On constate alors que ce type de contrôle est une succession de boucles ouvertes corrigées à chaque k période d'échantillonnage. La boucle ouverte est obtenue dans le cas où $k = 1$, c'est-à-dire que l'on n'applique que la première commande de la série calculée.




FIGURE 1.4 – Entrée/Sortie lors d'une itération d'un contrôle MPC *Source : [77]*

Contrairement aux méthodes décrites dans les sections précédentes, le MPC n'est pas une méthode d'optimisation en soi. C'est un schéma de contrôle avec horizon de prédiction glissant. Par contre, les méthodes d'optimisation comme le PMP ou la DP [78] peuvent être utilisées dans le cadre du MPC. Les méthodes MPC sont dépendantes de la qualité du modèle de prédiction. Dans le cas d'un modèle linéaire assez représentatif du système, l'implémentation en temps-réel devient possible. Autrement, la perte de représentativité par linéarisation engendre des erreurs importantes qui peuvent considérablement altérer l'optimalité de la solution [79]. Des méthodes utilisant des modèles de prédiction non-linéaires sont performantes [80],[81], mais requièrent un coût de calcul trop important.

Évidemment, cette méthode nécessite aussi des prédictions sur le trajet futur. Ces informations peuvent être acquises grâce aux outils de connectivité du véhicule comme le GPS [80] [82] [83]. D'autres méthodes se basent sur des méthodes de prédiction déterministes [78] ou probabilistes [84], [85], [86] ce qui constitue les méthodes SMPC.

Intrinsèquement, le schéma MPC n'a aucune valeur théorique du point de vue de l'optimisation. L'algorithme d'optimisation utilisé détermine la qualité de la solution. Théoriquement, l'optimalité n'est alors garantie que sur l'horizon de contrôle du schéma MPC. Les horizons de prédiction probabilistes des méthodes SMPC se situent entre quelques secondes [87] et la dizaine de secondes [88]. Les méthodes MPC garantissent alors une optimalité sur des fenêtres temporelles de dizaines de secondes. Du point de vue de l'optimisation globale, ceci revient à réduire considérablement l'espace de recherche de l'optimum. En effet, le MPC découpe

le trajet en plusieurs intervalles de dizaines de secondes, ce qui revient à sur-contraindre le problème, et donc n'offre aucune garantie d'optimalité sur le trajet complet.

1.3 Contribution : Le Principe du Maximum de Pontryagin appliqué en temps-réel avec des prédictions probabilistes

Une méthode d'*Energy Management* est nécessaire dans un véhicule hybride, mais elle est aussi déterminante quant à sa performance énergétique. La fabrication d'un véhicule hybride 'efficace' est impossible sans stratégie d'*Energy Management*, alors que le développement de solutions hautement performantes impose l'utilisation de techniques d'optimisation peu évidentes à embarquer. Comme nous l'avons vu dans cet état de l'art, les premières approches concernent alors des solutions à *base de règles* répondant à l'urgence d'une stratégie sans forcément garantir une optimalité mathématique mais, au fur et à mesure du développement, ces règles rejoignent un peu les principes des algorithmes basés sur la théorie du contrôle optimal.

Si les méthodes à *base de règles* pouvaient s'affranchir d'informations sur le futur trajet on pourrait s'en contenter, mais garantir un optimum de consommation sur tout un trajet nécessite une connaissance à priori sur ce trajet. Les prédictions sur le futur trajet ont été traitées de trois manières différentes. Soit par la mémorisation de situations fixes, soit par l'utilisation de moyens de connectivité du véhicule, ou alors par des modèles probabilistes pour anticiper la demande du conducteur.

Le développement de solutions d'*Energy Management* performantes pose deux questions : Quelle méthode d'optimisation utiliser ? Quelle approche de prédiction adoptée ? Bien que ces deux questions puissent être discutées séparément, la réponse à l'une impactera forcément l'autre.

1.3.1 Méthode d'optimisation

La manière la plus rigoureuse de modéliser la problématique de l'*Energy Management* est une modélisation en problème de contrôle optimal [89]. Il s'agit de ramener l'état de charge de la batterie d'un point initial à un point final tout en minimisant la consommation de l'ICE. Nous avons vu précédemment deux manières de résoudre un problème de contrôle optimal, l'utilisation du PMP et l'algorithme de DP.

D'une part, la DP a l'avantage de pouvoir garantir un optimum global du problème discrétisé. Cependant, cette méthode demande des efforts calculatoires inadaptés au contexte temps-réel. D'autre part, le PMP est un théorème qui garantit l'optimalité, qui peut être globale dans le cas de propriétés de convexité du problème. Du point de vue de l'implémentation, le PMP donne un schéma simple d'utilisation : la minimisation de l'Hamiltonien à chaque instant. En effet, l'Hamiltonien peut être simplement calculé en fonction des états du véhicule

pour chacune des solutions possibles, et il suffit alors de choisir la solution qui le minimise.

Les deux méthodes basées sur le PMP et la DP, nécessitent la connaissance à priori du trajet à optimiser. Pour la DP, les valeurs futures des demandes du conducteur sont nécessaires au calcul. Par contre, dans une méthode utilisant le PMP, les valeurs instantanées de la demande du conducteur sont utilisées dans la minimisation de l'Hamiltonien, et les incertitudes relatives à la prédiction peuvent être toutes ramenées à un seul paramètre, comme nous le verrons au chapitre 4. Pour ces raisons, la méthode adoptée dans cette thèse utilisera le PMP comme base de nos méthodes de résolution.

Les approches ayant pour base le PMP, sans prédiction du futur trajet, adaptent toutes d'une façon ou d'une autre la valeur de l'état adjoint initial. Les méthodes utilisant le PMP comme méthode de résolution globale (1.2.1.2) proposent l'adaptation de ce paramètre de façon à suivre une trajectoire de *SoC* pré-calculée. Les méthodes ECMS, inspirées par le PMP, ignorent la dynamique théorique du co-état et déterminent ses variations également à l'aide de régulations de la trajectoire de *SoC* sur des trajectoires prédéterminées.

Dans cette thèse l'approche adoptée est basée sur le PMP. L'initialisation du co-état, quant à elle, dépendra de la prédiction.

1.3.2 Approche prédictive

Les méthodes basées sur le PMP utilisant des prédictions essaient d'estimer l'initialisation du co-état en se basant sur des prédictions de paramètres du trajet, comme la vitesse maximale, le temps du trajet ou la puissance moyenne (1.2.2.1). Ces données sont alors utilisées pour choisir une valeur d'initialisation dans un tableau de valeurs prédéterminées. Ce type d'approche ne garantit cependant pas mathématiquement l'optimalité pour les multitudes de situations qu'un véhicule peut rencontrer.

D'autres méthodes utilisent des modèles mathématiques du comportement du conducteur. C'est notamment le cas des méthodes MPC. Ces modèles mathématiques sont construits hors-ligne à partir d'enregistrements sur des trajets spécifiques. Ces modèles ne peuvent pas garantir une représentativité de toutes les situations et toutes les dynamiques que peut rencontrer le véhicule. En plus, ces modèles sont validés en comparant directement les valeurs de la demande de puissance mesurées avec celles prédites, ce qui mène vers des horizons de prédiction de quelques dizaines de secondes au plus [88],[87]. Ceci implique que le contrôle optimal appliqué ne peut garantir l'optimalité que sur ces courtes durées.

Dans cette thèse, la connectivité du véhicule est utilisée en temps-réel, pas pour donner une prédiction fixe du trajet, mais plutôt pour alimenter un modèle probabiliste de demande de puissance. La validation du modèle probabiliste ne sera pas faite en comparant les prédictions des demandes avec les demandes mesurées, mais plutôt en comparant statistiquement le résultat de l'*Energy Management* avec la prédiction faite par l'algorithme issu du PMP probabiliste (chapitre 4).

Le modèle de prédiction probabiliste que nous avons développé au chapitre 4 sera paramétré en temps-réel, en fonction des prédictions issues de la connectivité du véhicule. Cette prédiction probabiliste sera alors insérée dans le problème de contrôle optimal en tant que variable aléatoire, menant à un problème de contrôle optimal probabiliste qui donne une distribution de probabilité comme solution. Cette approche permettra alors de prendre en compte les incertitudes liées aux prédictions. La décision de répartition d'énergie sur un trajet, qui revient à l'initialisation du co-état, sera alors prise en ayant une information sur les risques de décharge/surcharge possibles pour chaque performance visée.

Nous allons présenter dans le chapitre suivant les composants des véhicules utilisés et leur caractéristique sur lesquelles sera testée l'approche déterministe(chapitre 2) puis l'approche probabiliste (chapitre 2).

Modélisation sous forme de problème de contrôle optimal

Sommaire

2.1 Architectures hybrides parallèles	31
2.1.1 Architecture P2 : Ford Focus GTC2 48V	33
2.1.2 Architecture P0 : Audi A2 Hybride 330V	38
2.2 Modélisation du problème de l'Energy Management	42
2.2.1 Problème de contrôle optimal déterministe	43
2.2.2 Problème de contrôle optimal probabiliste	45

Afin d'appliquer le PMP, il est nécessaire de modéliser en équations la dynamique du système que l'on cherche à contrôler. En l'occurrence, il s'agit de décrire les dynamiques du véhicule hybride, et plus spécifiquement les éléments de la chaîne de traction les plus significatifs par rapport à la gestion d'énergie recherchée. Comme décrit dans l'introduction, il existe plusieurs types d'architectures hybrides. Les deux architectures les plus développées sont les architectures série et parallèle.

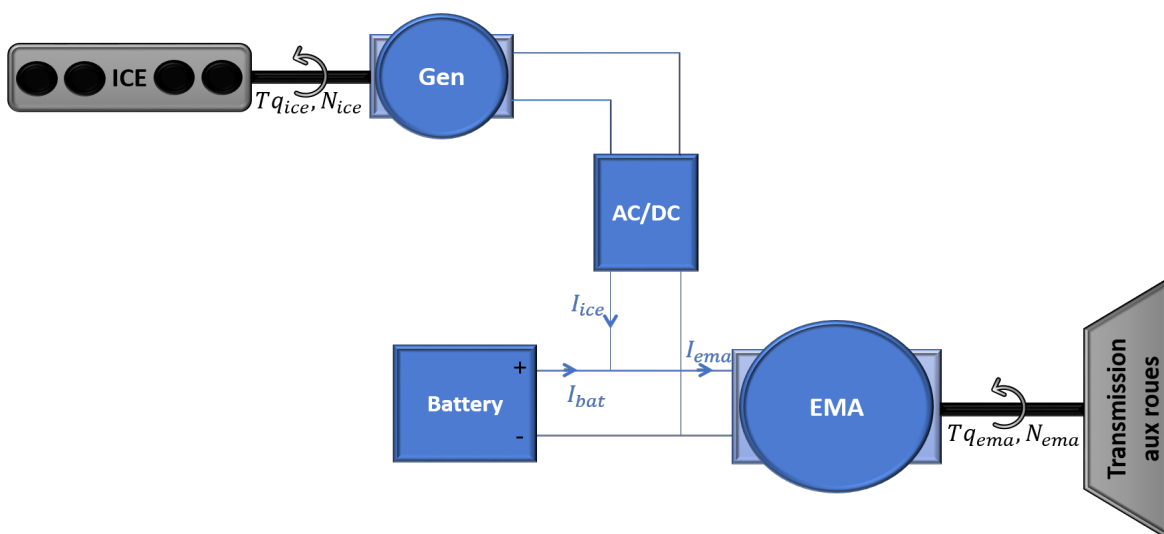


FIGURE 2.1 – Schéma de l'architecture d'une chaîne de traction série d'un véhicule hybride

L'architecture série, présentée sur la Figure 2.1, assure une transmission de la puissance mécanique aux roues par un arbre unique, la somme des puissances des différentes sources étant faite avant sur un noeud électrique. C'est-à-dire que la puissance est transmise de la première source d'énergie vers la seconde avant d'arriver sur les roues. La liaison entre l'ICE et l'EMA est une liaison électrique à travers un générateur qui convertie la puissance mécanique de l'ICE en une puissance électrique qui est ensuite injectée dans le circuit électrique de traction (et vice-versa lors des phases de freinage). Cette énergie électrique issue de l'ICE est alors ajoutée à la puissance de la batterie pour alimenter l'EMA qui se charge de la traction. Obligatoirement, les architectures série disposent d'une batterie et d'un moteur électrique plus puissants pour fournir la puissance et l'autonomie requises à la conduite, ce qui s'accompagne de la nécessité d'avoir un dimensionnement important en énergie et en puissance des composants électriques ce qui rend le coût du véhicule souvent plus élevé par rapport à une architecture parallèle.

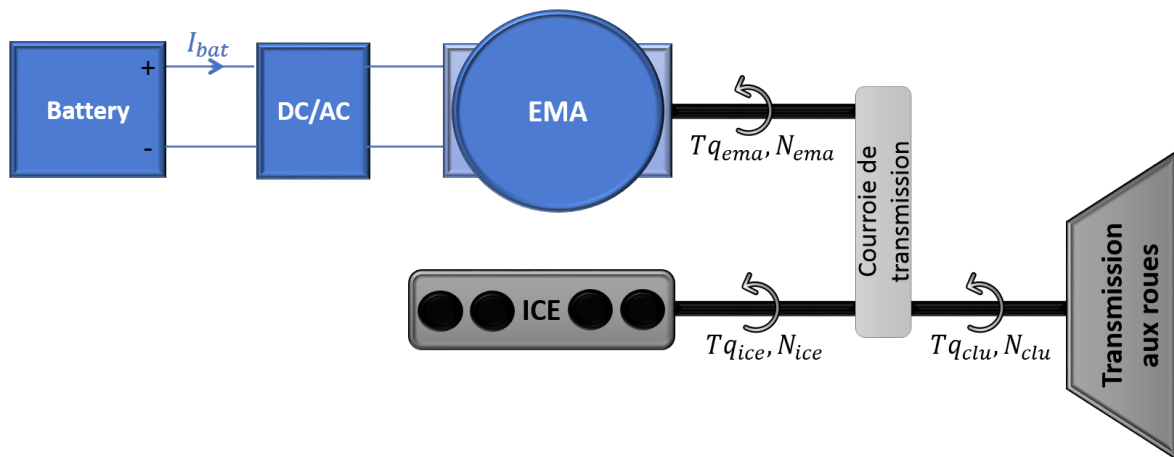


FIGURE 2.2 – Schéma de l'architecture d'une chaîne de traction parallèle d'un véhicule hybride

Pour une architecture parallèle (Figure 2.2), la puissance est transmise simultanément par l'ICE et l'EMA. Les deux sources de puissance forment un tandem et génèrent une somme de couple égale à la puissance de traction nécessaire à une vitesse commune donnée. En général, la liaison entre les deux moteurs se fait soit à travers une courroie de transmission, ou en positionnant le rotor de l'EMA directement sur l'arbre moteur dans les architectures ISG¹. Les vitesses de rotation des deux arbres moteurs sont alors proportionnelles. L'EMA dans une architecture parallèle est un complément de l'ICE. On peut alors avoir des composants électriques de moindre capacité par rapport aux architectures séries. Le coût d'un véhicule hybride parallèle est donc, en général, moins élevé, mais dépend du taux d'hybridation (ratio entre puissance électrique et autres sources non électrique installées). De plus, dans une architecture parallèle, l'ICE transmet directement sa puissance aux roues, ce qui réduit le trajet de puissance entre le moteur et les roues par rapport à une architecture série. L'architecture série est alors moins énergétiquement rentable, car l'énergie fournie par l'ICE passe par plusieurs conversions avec des rendements différents.

1. Integrated Starter-Generator

Dans cette thèse, la méthode proposée est appliquée à deux véhicules d'architecture parallèle, tels que choisis par le projet de Continental dans lequel s'inscrit cette thèse, et qui peut être justifié par les avantages en terme de rendement économique et énergétique qu'ont les véhicules à architecture parallèle.

Les architectures hybrides parallèles sont également de plusieurs types. Nous en étudierons deux présentant aussi deux niveaux d'hybridation différents.

2.1 Architectures hybrides parallèles

Les constructeurs automobiles et leurs fournisseurs ont mis en place une classification des différents types d'architectures hybrides parallèles selon la position de l'EMA dans la chaîne de traction. qui peut se trouver en 5 différents points, ce qui donne différentes architectures PX , comme décrit sur la Figure 2.3 :

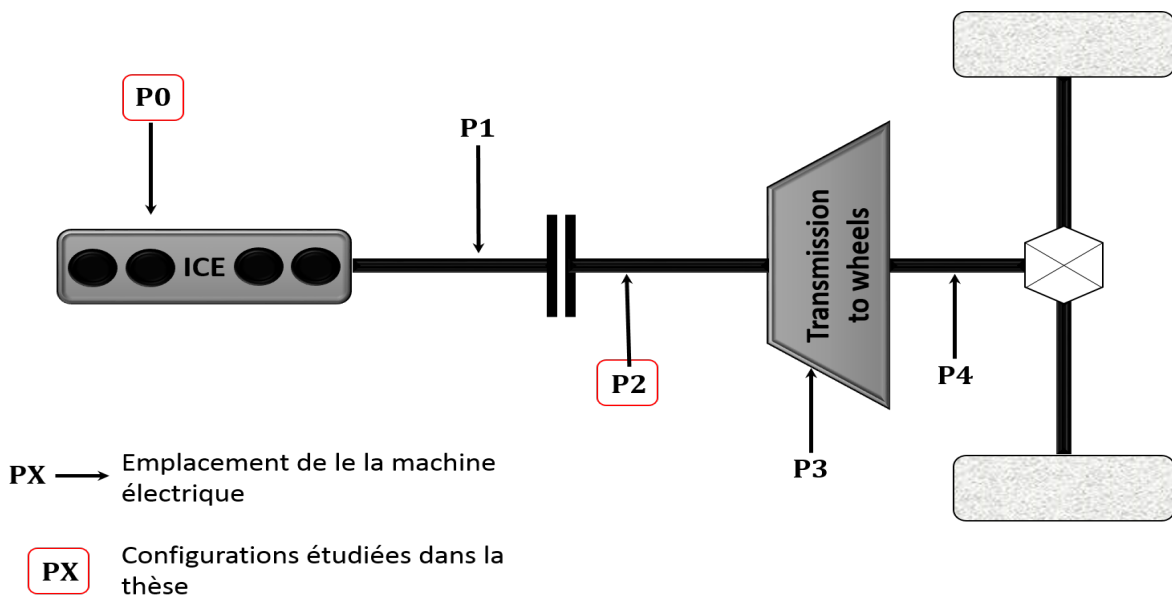


FIGURE 2.3 – Différentes architectures hybrides selon la position de la machine électrique dans la chaîne de traction

La Table 2.1 décrit brièvement les différentes architectures hybrides parallèles PX - acronymes proposés par AUDI devenus standards dans le milieu automobile. Il est à noter que les architectures $P0$ et $P1$ ne permettent pas de découpler l'ICE et l'EMA, contrairement aux architectures $P2$, $P3$ et $P4$. Ces trois dernières architectures ont alors l'avantage de permettre une traction purement électrique plus rentable. En effet, dans les architectures $P0$ et $P1$, la traction purement électrique doit se faire en entraînant une charge supplémentaire due au poids, aux pertes et frottements de l'ICE, alors que les architectures $P2$, $P3$, $P4$ permettent le découplage et l'arrêt de l'ICE. Ces différentes architectures impliquent alors des mises en équations différentes.

TABLE 2.1 – Description générale des différentes architectures hybrides parallèles selon la position de la machine électrique dans la chaîne de traction.

<i>P0</i>	L'EMA est connectée à l'ICE par une courroie sur la transmission des accessoires avant (FEAD)
<i>P1</i>	L'EMA est directement connectée à l'arbre moteur de l'ICE.
<i>P2</i>	L'EMA est connectée par une courroie ou intégrée entre l'ICE et la transmission. Les deux moteurs sont séparés par un embrayage et peuvent être découplés permettant une traction purement électrique.
<i>P3</i>	L'EMA est connectée à la transmission par un train d'engrenages. Cette architecture donne également la possibilité de découpler les deux moteurs.
<i>P4</i>	L'EMA est connectée à l'axe avant du véhicule par un train d'engrenages. Cette architecture donne également la possibilité de découpler les deux moteurs.

Un autre aspect de la classification est le taux d'hybridation, dans ce cas la valeur de la puissance électrique embarquée définit le degré d'hybridation et certaines fonctionnalités. Par exemple, dans une *Micro-Hybrid* la traction électrique n'est pas possible, alors qu'elle l'est dans une *Full-Hybrid*.

TABLE 2.2 – Valeurs des paramètres électriques pour les différents degrés d'hybridation

Taux d'hybridation	Micro-Hybrid	Mild-Hybrid	Full-Hybrid	Plug-in Hybrid
Tension de batterie [V]	12	48-160	200-400	300-400
Puissance moteur électrique [kW]	< 5	10-20	20-40	60-120
Type de batteries	PbAc	LI/NiMH	LI	LI

TABLE 2.3 – Fonctionnalités disponibles pour les différents degrés d'hybridation

Taux d'hybridation	Micro-Hybrid	Mild-Hybrid	Full-Hybrid	Plug-in Hybrid
Start/Stop	Oui	Oui	Oui	Oui
Traction hybride	Non	Oui	Oui	Oui
Freinage régénératif	Oui/Non	Oui	Oui	Oui
Traction électrique	Non	Oui/Non	Oui	Oui
Recharge de la batterie	Oui/Non	Oui	Oui	Oui
Recharge de la batterie sur secteur	Non	Non	Non	Oui

Dans cette thèse nous étudierons une architecture Mild-Hybrid *P2*, avec une Ford Focus GTC2 48V, et une Full-Hybrid *P0*, avec une Audi A2 Hybride 330V, ces véhicules étant utilisés comme "démocars" de test et de démonstration dans le cadre des travaux de Continental sur le développement de ces nouvelles stratégies de contrôle optimal des véhicules hybrides. Les composants pris en compte dans le modèle d'optimisation sont présentés dans les deux sections suivantes. Chaque composant est caractérisé par une cartographie décrivant

son comportement. Ces cartographies seront des données d'entrée de notre problème.

2.1.1 Architecture P2 : Ford Focus GTC2 48V

Le modèle de la Ford Focus GTC2 est fourni par Continental automotive sous le logiciel de simulation multiphysique AMESim. La Ford Focus GTC2 est un véhicule *Mild-Hybrid* d'architecture P2. L'ICE et l'EMA sont connectés par une courroie de transmission. L'ICE peut être découplé de la chaîne de traction en ouvrant l'embrayage C_0 , pendant les phases de traction purement électrique ou de freinage régénératif. Il est à noter que la partie électrique de la chaîne de traction contient à part, un réseau électrique 12V qui alimente les charges électriques auxiliaires (lampes, petits moteurs, accessoires). Ce modèle sera caractérisé par sa puissance P_{aux} et sera prise en compte dans les simulations complètes mais pas dans la formulation du problème principal.

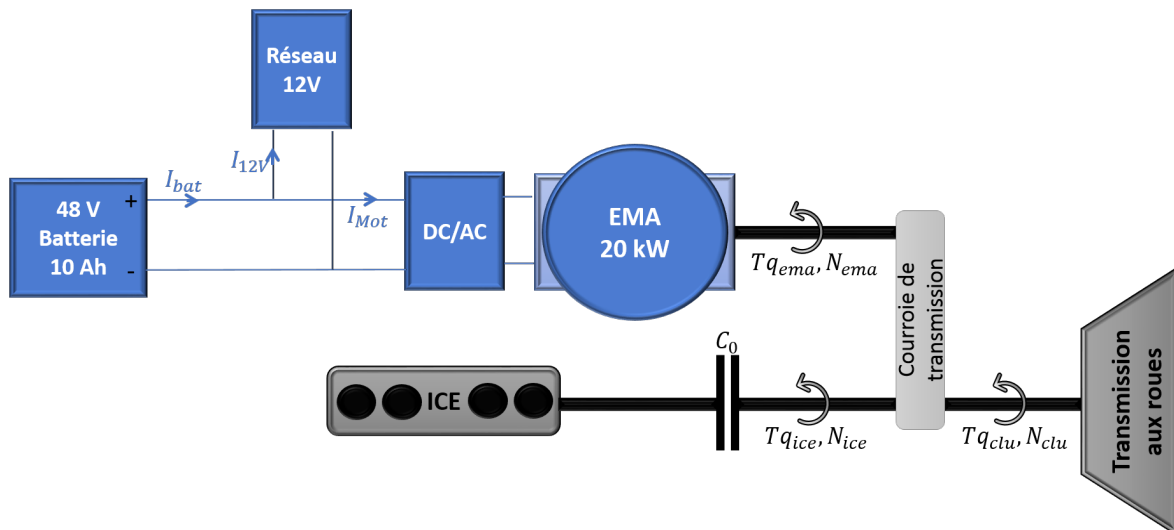


FIGURE 2.4 – Schéma de l'architecture de la Ford Focus GTC2 48V

Dans le modèle du véhicule fourni par Continental, les rendements ou les pertes des différents composants de la chaîne de traction sont décrits par des cartographies établies sur les bancs de tests. A noter qu'il s'agit d'une description de leurs comportements statiques et non dynamiques.

2.1.1.1 Partie électrique de la chaîne de traction

Batterie 48V La batterie utilisée est une 48V de 13 cellules Lithium-Ion de 10Ah. Les dynamiques de la batterie sont décrites par deux équations.

La première équation donne la dynamique de l'état de charge de la batterie SoC . Etant donné la capacité de charge maximale de la batterie Q_{max} , l'état de charge de la batterie à un instant t est le rapport entre la charge de la batterie à cet instant $q_{bat}(t)$ et sa charge

maximale. Le courant entrant dans la batterie étant la dérivée de la charge, et I_{bat} étant le courant sortant de la batterie, la charge de batterie q_{bat} est remplacée par l'intégrale du courant entrant $-I_{bat}$:

$$SoC(t) = \frac{q_{bat}}{Q_{max}} \quad (2.1)$$

$$= \frac{-1}{Q_{max}} \cdot \int_0^t I_{bat}(t) \cdot dt \quad (2.2)$$

On retient alors l'équation dynamique de l'état de charge en fonction du courant de la batterie (2.3).

$$S\dot{o}C(t) = \frac{-I_{bat}}{Q_{max}} \quad (2.3)$$

La seconde équation donne la tension aux bornes de la batterie. La tension de la batterie est la somme de trois tensions :

- OCV : La tension à vide qui est fonction de l'état de charge. La variation de OCV en fonction de l'état de charge est donnée sous forme de cartographie. Comme illustré sur la Figure 2.5, l' OCV varie de manière croissante entre 36V et 55V :

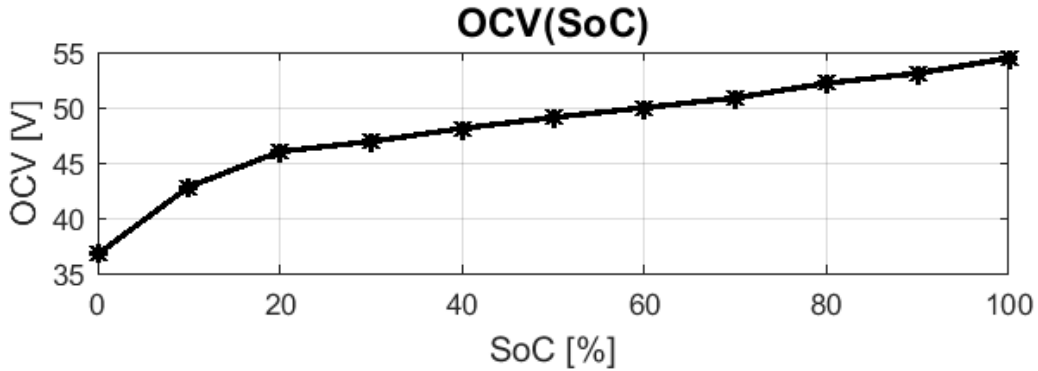


FIGURE 2.5 – Cartographie de variation de la tension à vide de la batterie 48V de la Ford Focus GTC2

- V_{ohm} : La chute de tension due à la résistance interne R_{int} de la batterie. R_{int} dépend de l'état de charge de la batterie et de la température T . La Figure 2.6 illustre les variations de la résistance interne de la batterie. Cette résistance est de l'ordre de 0.02Ω , et elle est croissante en fonction de l'état de charge. Il est à noter que dans ce cas précis, l'influence de la température sur la résistance interne est négligée. La tension V_{ohm} s'écrit en prenant en compte le sens du courant $V_{ohm} = -R_{int} \cdot I_{bat}$.
- V_{pol} : La tension de polarisation de la batterie est l'écart entre la tension électrochimique théorique et la tension réelle. Si la batterie fonctionne en mode générateur de courant, la tension de polarisation est positive, on est alors en sous-tension par rapport




FIGURE 2.6 – Cartographie de variation de la résistance interne de la batterie de la Ford Focus GTC2 48V

à la tension théorique. Dans le cas contraire, la tension de polarisation est négative, et on est alors en sur-tension par rapport à la valeur théorique. Cette tension est due, entre autre, à la résistance chimique des cellules. Les variations de cette tension sont données par deux cartographies donnant la polarisation négative dans le cas de la décharge ($I_{bat} \geq 0$), et la polarisation positive dans le cas d'une recharge ($I_{bat} \leq 0$) (Figure 2.7).

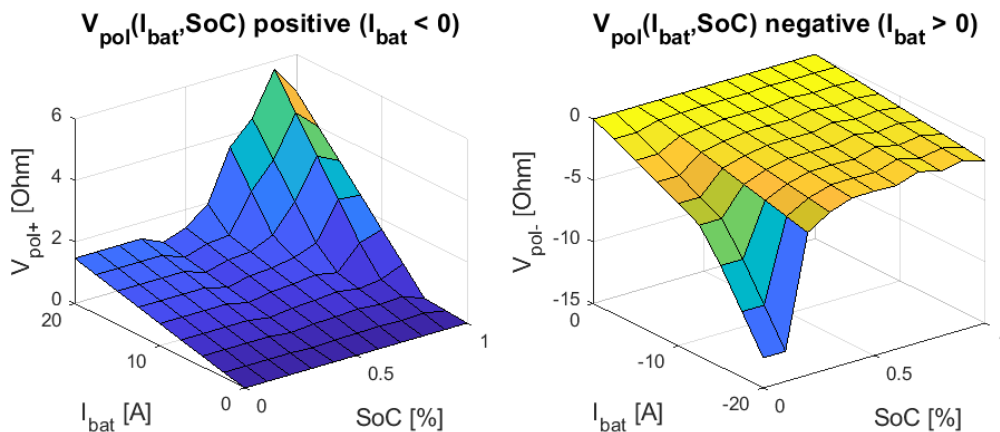


FIGURE 2.7 – Cartographies des variations de la tension de polarisation de la batterie 48V de la Ford Focus GTC2

Le circuit électrique équivalent de la batterie est présenté sur la Figure 2.8. En appliquant la loi des mailles on déduit la deuxième équation caractéristique de la batterie.

$$V_{bat} = OCV(SoC) - R_{int}(SoC, Temp) \cdot I_{bat} + V_{pol}(I_{bat}, SoC) \quad (2.4)$$

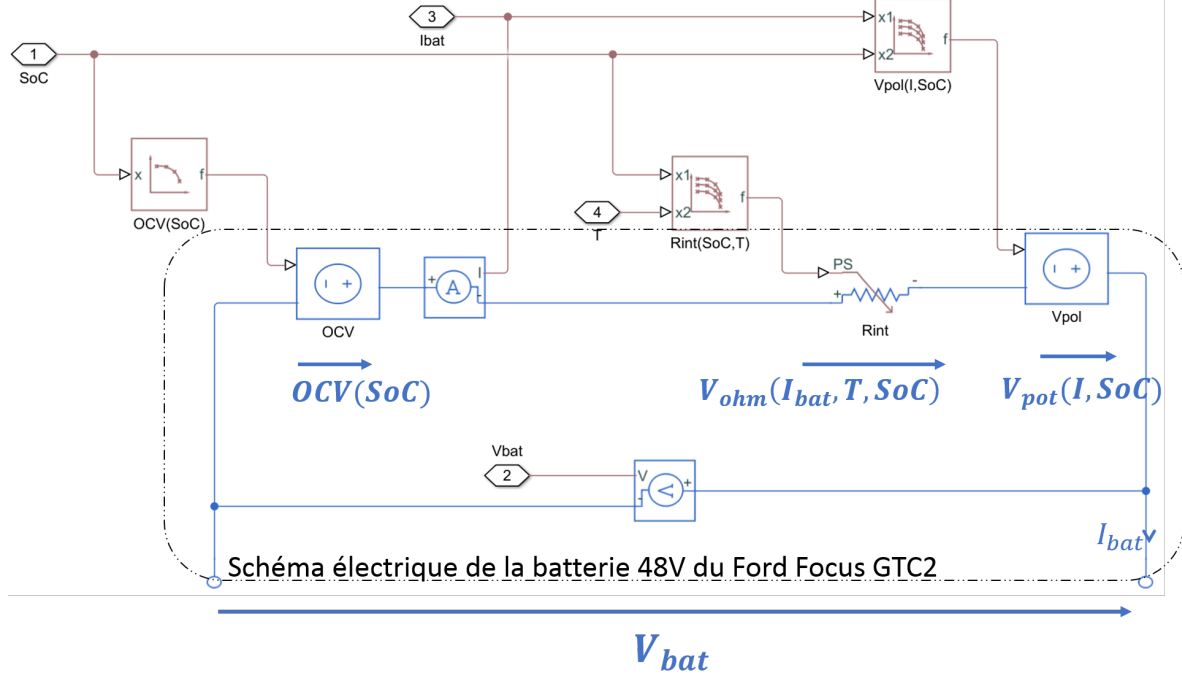


FIGURE 2.8 – Circuit électrique de la batterie de la Ford Focus GTC2 48V

Les équations (2.3) et (2.4) déterminent les variations de l'état de charge de la batterie et de la tension de la batterie.

Moteur électrique : L'EMA, dans le modèle utilisé, est caractérisé par sa cartographie de puissance. Cette cartographie donne la puissance électrique consommée en Watts $P_{elec}(Tq_{ema}, N_{ema}, V_{bat})$ en fonction de la tension à l'entrée de l'onduleur V_{bat} , et du couple fourni Tq_{ema} ainsi que de la vitesse de rotation du moteur N_{ema} .

2.1.1.2 Partie mécanique de la chaîne de traction

L'EMA génère un couple Tq_{ema} à la vitesse de rotation N_{ema} . Cette puissance mécanique est transmise à l'arbre moteur par une courroie de transmission de coefficient noté β . Ce coefficient dépend en général de la vitesse de rotation mais qui peut être simplifié dans le cas de la Ford Focus en un coefficient constant $\beta = 2.67$:

$$N_{ema} = \beta \cdot N_{ice} \quad (2.5)$$

Le couple issu de la machine électrique transmis à l'arbre moteur est alors $\beta \cdot Tq_{ema}$.




FIGURE 2.9 – Puissance électrique consommée par l’EMA et l’onduleur en fonction du couple fourni et de la vitesse du moteur à 48V

L’ICE peut être connecté/déconnecté à l’EMA par un embrayage. La variable C_0 définit l’état de l’embrayage.

$$\begin{cases} C_0 = 0 & \text{si embrayage ouvert} \\ C_0 = 1 & \text{si embrayage fermé} \end{cases}$$

La vitesse de rotation de l’ICE est égale à la vitesse en sortie de l’embrayage si $C_0 = 1$, et les couples des deux moteurs s’ajoutent à travers la courroie de transmission :

$$Tq_{clu} = C_0 \cdot Tq_{ice} + \beta Tq_{ema} \quad (2.6)$$

$$N_{clu} = N_{ice} \quad (2.7)$$

L’ICE fournit le couple Tq_{ice} à la vitesse N_{ice} en consommant la puissance thermique $P_{fuel}(Tq_{ice}, N_{ice})$. Cette puissance est proportionnelle au débit massique de carburant consommé (Figure 2.10).

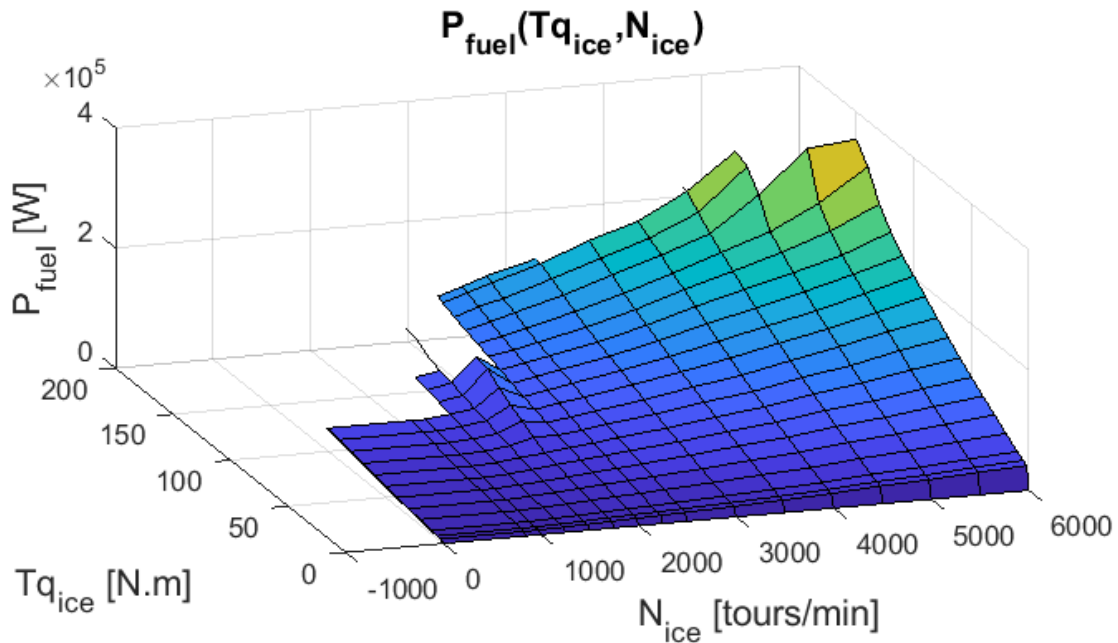


FIGURE 2.10 – Puissance thermique consommée par l’ICE fonction du couple fourni et de la vitesse du moteur dans la Ford Focus GTC2

2.1.2 Architecture P0 : Audi A2 Hybride 330V

Le modèle de l’Audi A2 Hybride 330V est fourni par l’IAM. De même que pour la Ford Focus, les données et paramètres du véhicule sont fournis sous la forme de cartographies, mais cette fois dans l’environnement Matlab. C’est un véhicule *Full-hybrid* d’architecture P0. L’EMA est connectée directement à l’ICE sur la transmission.

2.1.2.1 Partie électrique de la chaîne de traction

Batterie La partie électrique de l’Audi A2 est plus simple à modéliser par rapport à celle de la Ford Focus. Tout d’abord, il n’y a pas de réseau auxiliaire connecté à la batterie 330V de 7Ah. De plus, pour cette batterie, les tensions de polarisation ne sont pas prises en compte dans le modèle, et la résistance interne de la batterie est considérée constante. Sur la Figure 2.13 qui illustre les variations de la tension à vide de la batterie, on constate également que la tension à vide de la batterie peut être considérée comme une fonction linéaire de l’état de charge.

L’équation de variation de l’état de charge de la batterie est la même que (2.3) développée pour la Ford Focus (Figure 2.1) :

$$\dot{SoC}(t) = \frac{-I_{bat}}{Q_{max}} \quad (2.8)$$

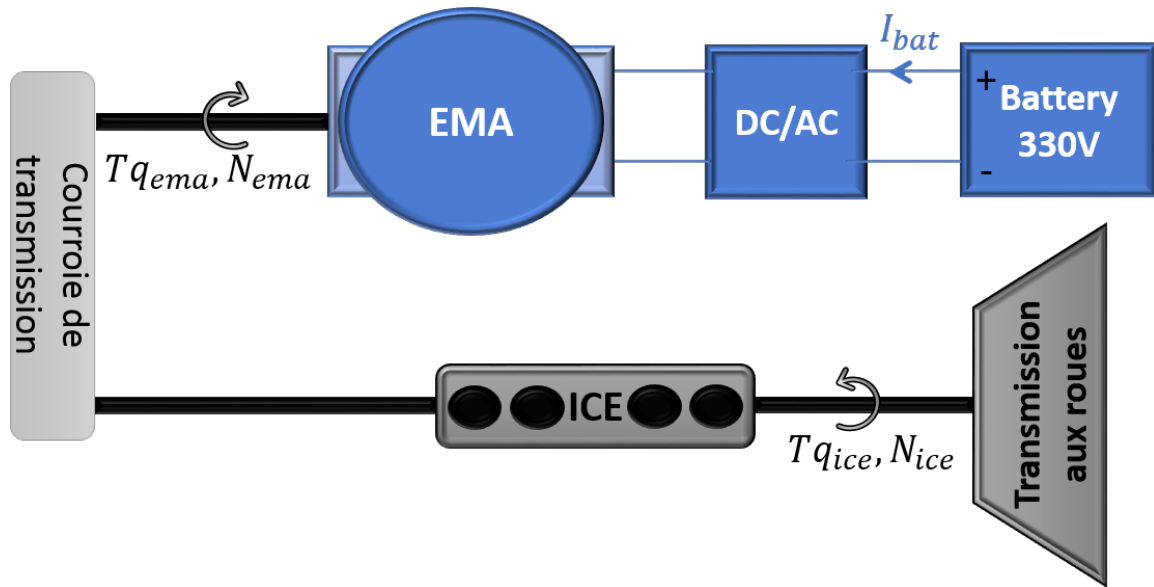


FIGURE 2.11 – Schéma de l'architecture de l'Audi A2 Hybride 330V

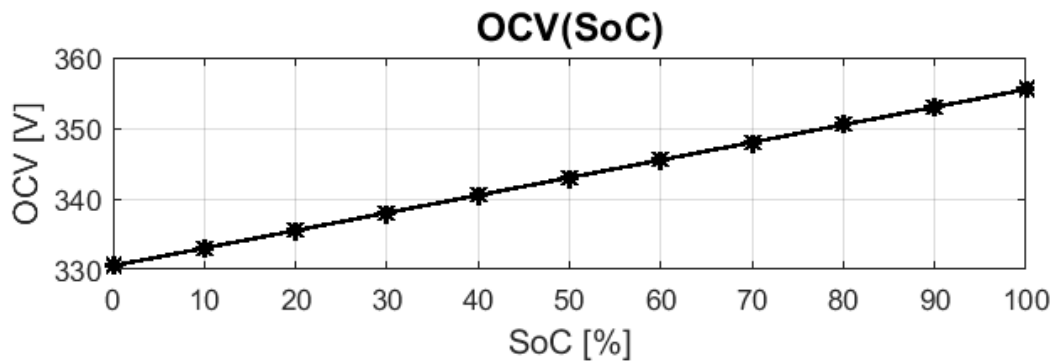


FIGURE 2.12 – Variation de la tension à vide de la batterie de l'Audi A2 Hybride 330V

La tension de la batterie est le résultat de la tension à vide OCV , dont la variation en fonction du SoC est illustrée sur la Figure 2.13, et de la chute de tension due à la résistance interne de la batterie. L'équation donnant la tension de la batterie est alors :

$$V_{bat} = OCV(SoC) - R_{int} \cdot I_{bat} \quad (2.9)$$

Machine électrique Comme pour le modèle de la Ford Focus, l'EMA est caractérisée par la cartographie de sa puissance électrique. A chaque point de fonctionnement on a $(Tq_{ema}, N_{ema}, V_{bat})$, V_{bat} étant la tension aux bornes de la batterie donc en entrée de l'onduleur, et Tq_{ema} et N_{ema} respectivement le couple fourni par la machine et la vitesse de rotation de la machine. Les variations de puissance électrique à 330V sont représentées sur la Figure 2.14.

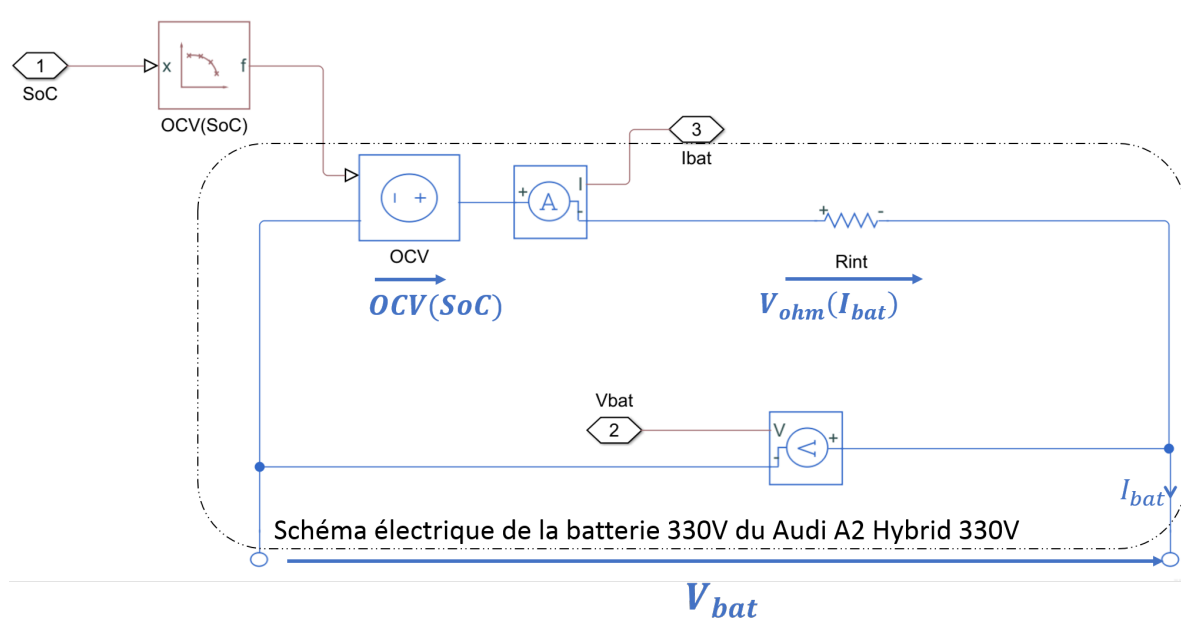


FIGURE 2.13 – Circuit électrique de la batterie de l'Audi A2 Hybride 330V




FIGURE 2.14 – Puissance électrique consommée par l'EMA et l'onduleur en fonction du couple fourni et de la vitesse du moteur à 330V.

2.1.2.2 Partie mécanique de la chaîne de traction

L'EMA est connectée à l'ICE à travers une courroie de coefficient unitaire sur la transmission avant. Les moteurs tournent à la même vitesse et leurs couples sont additionnés et transmis aux roues.

$$N_{ema} = N_{ice} = N_{clu} \quad (2.10)$$

$$Tq_{clu} = Tq_{ice} + Tq_{ema} \quad (2.11)$$

L'ICE consomme une puissance thermique $P_{fuel}(Tq_{ice}, N_{ice})$ illustrée sur la cartographie présentée sur la Figure 2.14.




FIGURE 2.15 – Puissance thermique consommée par l'ICE fonction du couple fourni et de la vitesse du moteur dans l'Audi A2 Hybrid

Il est à noter que cette puissance est proportionnelle au débit massique de carburant (tenant compte du pouvoir calorifique du carburant en question). Par ailleurs, une propriété importante qu'on peut observer visuellement sur la majorité des deux cartographies de l'ICE (Figure 2.10 et 2.15), est la convexité des fonctions de P_{fuel} par rapport au couple. Cette propriété sera importante pour l'obtention de l'optimum global du problème de contrôle optimal.

Une formulation commune pour les deux architectures peut maintenant être développée. En effet, en mettant $\beta = 1$ et $C_0 = 1$ pour l'Audi A2 Hybrid, on peut écrire les équations

mécaniques communes pour les deux architectures :

$$N_{ice} = \frac{N_{ema}}{\beta} = N_{clu} \quad (2.12)$$

$$Tq_{clu} = C_0 \cdot Tq_{ice} + \beta \cdot Tq_{ema} \quad (2.13)$$

Concernant les équations électriques, la variation de l'état de charge est décrite par la même équation, par contre, la présence du réseau 12V et la considération de la tension de polarisation en plus de la variation de la résistance interne de la batterie dans la Ford Focus, marquent la différence entre les deux modèles. Nous pouvons cependant écrire une formulation commune aux deux véhicules en considérant la variable V_{pol} (tension de polarisation) nulle pour l'Audi A2. Les équations communes pour les deux architectures s'écrivent :

$$S\dot{o}C(t) = \frac{-I_{bat}}{Q_{max}} \quad (2.14)$$

$$V_{bat} = OCV(SoC) - R_{int} \cdot I_{bat} + V_{pol} \quad (2.15)$$

Les équations (2.12) et (2.14) décrivent alors les dynamiques des architectures des deux véhicules présentés. Le tableau 2.4 liste les différentes valeurs des paramètres.

TABLE 2.4 – Valeurs des paramètres principaux utilisés pour le modèle Audi/Ford.

	Ford Focus GTC2 48V	Audi A2 Hybrid 330V
C_0	$C_0 = 0$ si embrayage ouvert $C_0 = 1$ si embrayage fermé	$C_0 = 1$
β	$\beta = 2.67$	$\beta = 1$
V_{pol}	Figure (2.7)	$V_{pol} = 0$
R_{int}	Figure (2.6)	$R_{int} = 0.1 \Omega$
Q_{max}	$Q_{max} = 10Ah$	$Q_{max} = 7Ah$
OCV	Figure (2.5)	Figure (2.13)

2.2 Modélisation du problème de l'*Energy Management*

L'objectif de l'*Energy Management* est de trouver, sur un trajet donné, la répartition de couple qui minimise la consommation de carburant tout en garantissant un état de charge final donné de la batterie. Le trajet est caractérisé par les demandes de couple et les vitesses de rotation correspondantes au niveau de la transmission (Tq_{clu}, N_{clu}) demandées par le conducteur pendant le trajet. Dans un premier temps, ces grandeurs seront considérées connues, dans ce qui constituera le problème déterministe de contrôle optimal. Cette version déterministe du

problème qui fait abstractions des incertitudes des prédictions, sera utilisées pour analyser le potentiel de la méthode, et identifier les caractéristiques des solutions optimales. Ensuite, les demandes de couples et de vitesses pendant le trajet (forcément incertaines dans leur prédiction ou entachées d'erreur) seront considérées comme des variables aléatoires paramétrées par la connectivité du véhicule, ce qui transforme le problème de contrôle optimal en un problème de contrôle optimal probabiliste.

2.2.1 Problème de contrôle optimal déterministe

Dans cette partie, nous allons définir le problème de contrôle optimal lié à notre problème d'Energy management, selon la formulation générale (1.1).

Le problème d'Energy management consiste à minimiser la puissance thermique de l'ICE qui dépend du couple fourni et de la vitesse de rotation. Le critère intégral à minimiser est alors :

$$J = \int_0^{T_f} P_{fuel}(T_{q_{ice}}, N_{ice}).dt \quad (2.16)$$

Il reste alors à définir la commande du problème de contrôle optimal. Les commandes dans la problématique de l'Energy management sont les consignes de couple des moteurs, $T_{q_{ice}}$ et $T_{q_{ema}}$ (en plus de la commande de l'embrayage C_0 pour l'architecture P2). Ces commandes doivent à tout moment être liées par l'équation :

$$T_{q_{clu}} = C_0.T_{q_{ice}} + \beta.T_{q_{ema}} \quad (2.17)$$

où $T_{q_{clu}}$ est la demande de couple par le conducteur. Cette liaison permet de réduire le nombre de commandes. Seule une consigne de couple de l'ICE ou de l'EMA sera une commande du problème du contrôle optimal et sera calculée par l'algorithme du PMP, l'autre consigne déduite à partir de l'équation (2.17) pour satisfaire la demande du conducteur. Le moteur électrique ayant un temps de réponse plus rapide que le moteur thermique, il peut répondre plus rapidement aux demandes du conducteur. Nous choisissons le couple thermique $T_{q_{ice}}$ comme la commande du problème de contrôle optimal. Dans la formulation du problème le couple électrique est remplacé par son expression issu de (2.17) :

$$T_{q_{ema}} = \frac{T_{q_{clu}} - C_0.T_{q_{ice}}}{\beta} \quad (2.18)$$

Les contraintes des limites des couples électriques peuvent aussi être exprimer en une seule contrainte sur la variable de commande de contrôle optimal $T_{q_{ice}}$. Les contraintes de limitations de couples s'écrivent :

$$T_{q_{ice}}^{min} \leq T_{q_{ice}} \leq T_{q_{ice}}^{max} \quad (2.19)$$

$$T_{q_{ema}}^{min} \leq T_{q_{ema}} = \frac{T_{q_{clu}} - C_0.T_{q_{ice}}}{\beta} \leq T_{q_{ema}}^{max} \quad (2.20)$$

La commande Tq_{ice} , pour $C_0 = 1$ est alors soumise aux deux limitations :

$$Tq_{ice}^{min} \leq Tq_{ice} \leq Tq_{ice}^{max} \quad (2.21)$$

$$\frac{Tq_{clu} - \beta \cdot Tq_{ema}^{max}}{C_0} \leq Tq_{ice} \leq \frac{Tq_{clu} - \beta \cdot Tq_{ema}^{min}}{C_0} \quad (2.22)$$

Dans le cas $C_0 = 0$, l'embrayage est ouvert et seule la machine électrique assure la traction. La contrainte sur le couple ICE n'a alors plus de sens.

En écrivant :

$$Tq_{min} = \max\left(\frac{Tq_{clu} - \beta \cdot Tq_{ema}^{max}}{C_0}, Tq_{ice}^{min}\right) \quad (2.23)$$

$$Tq_{max} = \min\left(\frac{Tq_{clu} - \beta \cdot Tq_{ema}^{min}}{C_0}, Tq_{ice}^{max}\right) \quad (2.24)$$

Les deux contraintes de limitations sont alors exprimées en une seule

$$Tq_{min} \leq Tq_{ice} \leq Tq_{max}$$

Les vitesses de rotation des moteurs sont proportionnelles à la vitesse imposée par le conducteur :

$$N_{ema} = \beta \cdot N_{clu} \quad (2.25)$$

$$N_{ice} = N_{clu} \quad (2.26)$$

L'autre objectif est de garantir un état de charge final SoC_f , à la fin du trajet. Il s'agit alors de contrôler l'état de charge de la batterie à partir d'un état SoC_0 vers l'état de charge souhaité. L'équation (2.14) donne la dynamique de l'état de charge. Pour y faire apparaître les commandes ou l'état du système, le courant sortant de la batterie est écrit comme la puissance fournie par la batterie P_{bat} divisée par la tension aux bornes de la batterie. Cette puissance est ensuite séparée entre la puissance transmise au moteur P_{elec} et la puissance auxiliaire. La tension de la batterie est remplacée par l'expression de l'équation (2.14) :

$$I_{bat} = \frac{P_{bat}}{V_{bat}} \quad (2.27)$$

$$= \frac{P_{elec}(Tq_{ema}, N_{ema}) + P_{aux}}{V_{bat}} \quad (2.28)$$

$$= \frac{P_{elec}(Tq_{ema}, N_{ema}) + P_{aux}}{OCV(SoC) - R_{int} \cdot I_{bat} + V_{pol}} \quad (2.29)$$

P_{aux} étant la puissance électrique fournie à l'éventuel réseau 12V.

Finalement le problème de contrôle optimal de l'Energy management, sur un trajet de durée T_f défini par les demandes du conducteur (Tq_{clu}, N_{clu}) est écrit :

$$\begin{aligned}
\min_{Tq_{ice}} \quad & J = \int_0^{T_f} P_{fuel}(Tq_{ice}, N_{clu}).dt \\
\text{sous contraintes : } \quad & \dot{SoC}(t) = \frac{-1}{Q_{max}} \frac{P_{elec}(\frac{1}{\beta}(Tq_{clu} - C_0.Tq_{ice}), \beta.N_{clu}) + P_{aux}}{OCV(SoC) - R_{int}.I_{bat} + V_{pol}} \\
& SoC(T_f) = SoC_f \\
& SoC(0) = SoC_0 \\
& Tq_{min} \leq Tq_{ice} \leq Tq_{max} \\
& SoC_{min} \leq SoC(t) \leq SoC_{max}
\end{aligned} \tag{2.30}$$

Notons aussi la présence de contraintes sur l'état SoC . Ces contraintes sont généralement compliquées à prendre en compte en utilisant le PMP.

2.2.2 Problème de contrôle optimal probabiliste

Le trajet, sur lequel le contrôle optimal est appliqué, est défini par les demandes de couples et de vitesses pendant la durée du trajet. On ne peut pas obtenir ces valeurs à l'avance, car cela reviendrait à prédire le comportement futur du conducteur et son trajet choisi. Néanmoins en utilisant la connectivité des véhicules, on peut obtenir des estimations, que l'on va modéliser dans cette thèse par des variables aléatoires. En notant $(\hat{T}q_{clu}, \hat{N}_{clu})$ les variables aléatoires de notre problème de contrôle optimal probabiliste, le problème précédent (2.30) peut être réécrit par :

$$\begin{aligned}
\min_{Tq_{ice}} \quad & J = \int_0^{T_f} P_{fuel}(Tq_{ice}, \hat{N}_{clu}).dt \\
\text{sous contraintes : } \quad & \dot{SoC}(t) = \frac{-1}{Q_{max}} \frac{P_{elec}(\frac{1}{\beta}(\hat{T}q_{clu} - C_0.Tq_{ice}), \beta.\hat{N}_{clu}) + P_{aux}}{OCV(SoC) - R_{int}.I_{bat} + V_{pol}} \\
& SoC(T_f) = SoC_f \\
& SoC(0) = SoC_0 \\
& \hat{T}q_{min} \leq Tq_{ice} \leq \hat{T}q_{max} \\
& SoC_{min} \leq SoC(t) \leq SoC_{max}
\end{aligned} \tag{2.31}$$

Il est à noter que les saturations du couple de commande $T_{q_{max}}$ et $T_{q_{min}}$ deviennent des variables probabilistes. En effet, ses variables sont construites en fonction de $\hat{T}_{q_{clu}}$ dans les équations (2.23) et (2.24).

Le critère à minimiser, les contraintes dynamiques, ainsi que la contrainte sur les limites du couple électrique deviennent probabilistes. La variable aléatoire dans la contrainte dynamique fait que l'état de charge final devient également une variable aléatoire. On a :

$$SoC(T_f) = \int_0^{T_f} \dot{SoC}(t).dt + SoC(0) \quad (2.32)$$

$$= \int_0^{T_f} \frac{-1}{Q_{max}} \frac{P_{elec}(\frac{1}{\beta}(\hat{T}_{q_{clu}} - C_0 \cdot T_{q_{ice}}), \beta \cdot \hat{N}_{clu}) + P_{aux}}{OCV(SoC) - R_{int} \cdot I_{bat} + V_{pol}}.dt + SoC(0) \quad (2.33)$$

La puissance électrique devient alors aussi fonction d'une variable aléatoire ; ceci fait que la dynamique de SoC devient elle-même une variable aléatoire. L'état de charge final est donc bien une variable aléatoire, étant donné qu'il est égal à une somme continue de variables aléatoires. Il en découle que l'expression de la contrainte sur l'état de charge final ne peut pas être déterministe. Nous définissons alors une tolérance d'erreur ϵ , la contrainte sur la probabilité de satisfaction de la l'état final de charge souhaité est :

$$P(SoC(T_f) = SoC_f) \geq 1 - \epsilon \quad (2.34)$$

De même pour la contrainte sur les limites du couple :

$$P(\hat{T}_{q_{min}} \leq T_{q_{ice}} \leq \hat{T}_{q_{max}}) \geq 1 - \epsilon \quad (2.35)$$

Concernant le critère à minimiser, il est lui aussi une somme de variables aléatoires et est donc une variable aléatoire. Le minimum d'une variable aléatoire est une variable aléatoire, qui peut être calculée en utilisant les statistiques de l'ordre [90]. Les statistiques de l'ordre est une discipline mathématique assez complexe que nous choisissons d'éviter. On choisit donc de minimiser son espérance mathématique :

$$J = E \left(\int_0^{T_f} P_{fuel}(T_{q_{ice}}, \hat{N}_{clu}).dt \right) \quad (2.36)$$

Ainsi, le problème de contrôle optimal de l'*Energy management*, sur un trajet de durée T_f défini par les estimations probabilistes des demandes du conducteur en tant que variables aléatoires $(\hat{T}_{q_{clu}}, \hat{N}_{clu})$ peut être formulé par :

$$\begin{aligned}
\min_{T_{q_{ice}}} \quad & J = E \left(\int_0^{T_f} P_{fuel}(T_{q_{ice}}, \hat{N}_{clu}) \cdot dt \right) \\
\text{sous contraintes : } \quad & \dot{SoC}(t) = \frac{-1}{Q_{max}} \frac{P_{elec} \left(\frac{1}{\beta} (\hat{T}q_{clu} - C_0 \cdot T_{q_{ice}}), \beta \cdot \hat{N}_{clu} \right) + P_{aux}}{OCV(SoC) - R_{int} \cdot I_{bat} + V_{pol}} \\
& P(SoC(T_f) = SoC_f) \geq 1 - \epsilon \\
& SoC(0) = SoC_0 \\
& P(\hat{T}q_{min} \leq T_{q_{ice}} \leq \hat{T}q_{max}) \geq 1 - \epsilon \\
& SoC_{min} \leq SoC(t) \leq SoC_{max}
\end{aligned} \tag{2.37}$$

Les deux véhicules étudiés ayant des architectures hybrides-parallèles cela mène à des équations semblables pour lesquelles une formulation commune a pu être développée. Cependant, il faut garder à l'esprit une différence majeure dans la lecture du problème de contrôle optimal commun, qui fait que C_0 (qui modélise le contrôle de l'ouverture/fermeture de l'embrayage) est un paramètre constant pour la formulation appliquée à l'Audi A2, alors qu'il désigne une variable de commande supplémentaire pour la Ford Focus. Ceci devra être respecté pendant la résolution du problème du contrôle optimal. La partie stochastique sera développée (chapitre 4) après avoir abordé le cas déterministe du chapitre suivant.

Les simulations exposées dans la thèse seront réalisées dans un environnement Matlab-Simulink[91], sur un PC Windows 7 avec un processeur Intel i7 3.4Ghz.

PMP Energy Management déterministe

Sommaire

3.1	Résolution du problème de contrôle optimal	50
3.1.1	Hypothèses sur les variables électriques dans le modèle de contrôle optimal	51
3.1.2	Commande de l'embrayage C_0	55
3.1.3	Initialisation du co-état : Bases théoriques de l'algorithme de tirs	58
3.2	Structure algorithmique du <i>PMP Energy management</i>	61
3.2.1	Méthode indirecte de tirs	62
3.2.2	Structure de l'algorithme en temps-réel	63
3.3	Évaluation du <i>PMP Energy Management</i> par simulation	66
3.3.1	Simulation sur le modèle de référence	66
3.3.2	Simulations de La Ford Focus GTC2 avec le modèle complet AMESim : Etude comparative avec la méthode CostBased.	74
3.3.3	Conclusions	79

Dans ce chapitre, la résolution du problème déterministe sera développée. Une première partie de la résolution est analytique en appliquant le théorème du *Principe du Maximum de Pontryagin*. La deuxième partie de la résolution sera algorithmique, dû au fait que les données du véhicule sont disponibles sous forme de cartographies. La solution développée sera simulée sur les deux véhicules, et comparée à d'autres algorithmes.

Ce chapitre applique le PMP au problème de l'*Energy Management* sous une hypothèse déterministe, c'est-à-dire que les demandes de couples et vitesses du conducteur durant le trajet futur sont considérées connues à l'avance. La finalité de la thèse étant une méthode permettant d'obtenir des solutions optimales dans le cadre de prédictions incertaines, nous commençons de manière déterministe dans le but d'évaluer le potentiel de la méthode non altéré par les incertitudes des prédictions. Ces prédictions des demandes du conducteur sont considérées dans cette partie, parfaites et précises à 100%. La solution qui en découlera sera alors comparée à un algorithme de DP qui garantit l'optimum global du problème discrétisé, et qui sera considéré comme solution de référence. Cela permettra de jauger l'optimalité que peut offrir notre méthode basée sur le PMP dans un cas idéal. La méthode sera aussi simulée sur un modèle de véhicule complet et comparée à la méthode "Cost-Based", méthode à base

d'optimisation temps-réel des experts de chez Continental Automotive, ce qui permettra de tester le PMP dans un contexte plus proche du réel.

Notre méthode que, l'on nommera *PMP Energy Management* déterministe, est développée en se basant sur la résolution du problème de contrôle optimal formulé par les équations (2.30) par le PMP. L'algorithme sous-jacent est alors décrit et simulé dans le cadre de trajets différents, pour les deux véhicules présentés dans le chapitre précédent et pour les différentes hypothèses adoptées pour la résolution (Cf 3.1.1).

3.1 Résolution du problème de contrôle optimal

La formulation développée lors du chapitre précédent est commune aux deux modèles de véhicules traités. Ceci nous permettra de procéder à une résolution commune aux deux problèmes. Cependant, le cas de la Ford Focus d'architecture P2, ayant comme variable de commande supplémentaire C_0 le contrôle de l'embrayage, nécessite une discussion spécifique que nous abordons dans 3.1.2 .

La contrainte sur la variable d'état $SoC_{min} \leq SoC \leq SoC_{max}$ est relaxée dans la résolution discutée dans ce chapitre. Cette relaxation est adoptée afin d'éviter une complexité de résolution qui sera au final inutile. En effet, la résolution d'un problème de contrôle optimal avec contrainte sur l'état nécessite des calculs supplémentaires qui ne se limitent plus à la minimisation du Hamiltonien, et qui peut donc devenir inadapté pour une implémentation en temps réel [92].

Le problème de contrôle optimale s'écrit alors :

$$\begin{aligned}
 \min_{Tq_{ice}} \quad & J = \int_0^{T_f} P_{fuel}(Tq_{ice}, N_{clu}) \cdot dt \\
 \text{sous contraintes :} \quad & \dot{SoC}(t) = \frac{-1}{Q_{max}} \frac{P_{elec}(\frac{1}{\beta}(Tq_{clu} - C_0 \cdot Tq_{ice}), \beta \cdot N_{clu}) + P_{aux}}{OCV(SoC) - R_{int} \cdot I_{bat} + V_{pol}} \\
 & SoC(T_f) = SoC_f \\
 & SoC(0) = SoC_0 \\
 & Tq_{min} < Tq_{ice} < Tq_{max}
 \end{aligned} \tag{3.1}$$

Selon le *Principe de Maximum de Pontryaguin*, la résolution du problème de contrôle optimal nécessite la définition de l'Hamiltonien du problème et de l'état adjoint ou co-état (Section 1.2.1.2). L'Hamiltonien du problème est :

$$H(SoC, Tq_{ice}, C_0, \lambda) = P_{fuel}(Tq_{ice}, N_{clu}) - \frac{\lambda}{Q_{max}} \frac{P_{elec}(\frac{1}{\beta}(Tq_{clu} - C_0 \cdot Tq_{ice}), \beta \cdot N_{clu}) + P_{aux}}{OCV(SoC) - R_{int} \cdot I_{bat} + V_{pol}} \quad (3.2)$$

Où λ est la variable du co-état associée à la variable d'état SoC . Elle vérifie l'équation différentielle :

$$\frac{\partial H}{\partial SoC} = -\dot{\lambda} \quad (3.3)$$

Notons $\lambda_0 = \lambda(0)$. C'est l'initialisation de l'état adjoint qu'il faudra déterminer (Cf 3.1.3).

Les commandes qui minimisent à chaque instant l'Hamiltonien sont alors :

$$(Tq_{ice}^{opt}(t), C_0^{opt}) = \arg \min_{Tq_{ice}, C_0} H(SoC, Tq_{ice}, C_0, \lambda) \quad (3.4)$$

Dans le cas de l'Audi A2, où seule Tq_{ice} est une commande :

$$Tq_{ice}^{opt}(t) = \arg \min_{Tq_{ice}} H(SoC, Tq_{ice}, \lambda) \quad (3.5)$$

Cependant, nous prendrons comme hypothèse de travail pour le cas général donné par l'équation (3.4), que la solution pourra être calculée en résolvant directement et de manière indépendante l'équation (3.5), et ainsi le calcul de C_0^{opt} pourra être entièrement explicité en 3.1.2.

3.1.1 Hypothèses sur les variables électriques dans le modèle de contrôle optimal

Afin de pouvoir déterminer la solution optimale, il est nécessaire de calculer λ en utilisant l'équation (3.3). Il faut donc exprimer la dérivée partielle de l'Hamiltonien H par rapport à SoC . Les termes composant l'expression de l'Hamiltonien sont :

- $P_{fuel}(Tq_{ice}, N_{clu})$: Puissance thermique du moteur ICE qui ne dépend pas de SoC
- $P_{elec}(\frac{1}{\beta}(Tq_{clu} - C_0 \cdot Tq_{ice}), \beta \cdot N_{clu}, V_{bat})$: Puissance électrique consommée par le moteur EMA qui dépend de la tension de la batterie, et donc indirectement de SoC .
- P_{aux} : Puissance électrique consommée par le réseau auxiliaire qui ne dépend pas de SoC .
- $OCV(SoC) - R_{int} \cdot I_{bat} + V_{pol}$: L'expression de la tension de la batterie qui dépend directement de SoC à travers la tension à vide OCV et indirectement à travers le courant de la batterie I_{bat} .

Le calcul de la variation de l'Hamiltonien par rapport au SoC donne :

$$\frac{\partial H}{\partial SoC} = \frac{\lambda}{Q_{max} \cdot V_{bat}} \frac{\partial V_{bat}}{\partial SoC} \left(\frac{P_{elec} + P_{aux}}{V_{bat}} + \frac{\partial P_{elec}}{\partial V_{bat}} \right) \quad (3.6)$$

Le terme $\frac{\partial P_{elec}}{\partial V_{bat}}$ est négligé dans ce qui suit devant le terme $\frac{P_{elec}}{V_{bat}}$. En effet, à part sur les bords de la cartographie de puissance P_{elec} , ce terme est négligeable. La Figure 3.1 montre le pourcentage de $\frac{P_{elec}}{V_{bat}}$ que représente $\frac{\partial P_{elec}}{\partial V_{bat}}$ pour l'EMA de la Ford Focus. Nous pouvons y voir que $\frac{\partial P_{elec}}{\partial V_{bat}}$ représente moins de 5% de $\frac{P_{elec}}{V_{bat}}$ à part sur quelques bords.

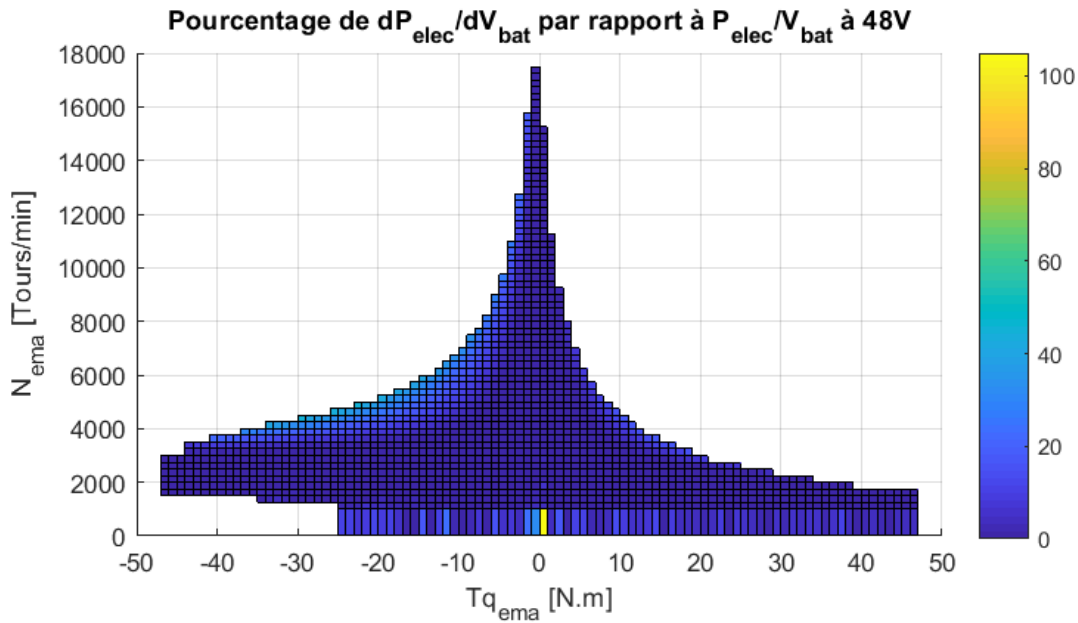


FIGURE 3.1 – Pourcentage de $\frac{P_{elec}}{V_{bat}}$ que représente $\frac{\partial P_{elec}}{\partial V_{bat}}$, pour l'EMA de la Ford Focus à 48V, en fonction des couples et vitesses de rotation.

L'impact de SoC dans l'Hamiltonien réside donc dans l'expression de la tension batterie :

$$V_{bat} = OCV(SoC) - R_{int} \cdot I_{bat} + V_{pol}$$

En effet, négliger les variations de P_{elec} par rapport à V_{bat} revient à négliger les variations de P_{elec} par rapport à SoC . Dans la suite, $\frac{\partial P_{elec}}{\partial SoC}$ est négligée.

La dérivée partielle de l'Hamiltonien par rapport à SoC est alors :

$$\frac{\partial H}{\partial SoC} = \frac{\lambda}{Q_{max} V_{bat}^2} (P_{elec} + P_{aux}) \frac{\partial V_{bat}}{\partial SoC} \quad (3.7)$$

Ce qui donne l'expression de l'équation différentielle donnant le co-état :

$$\dot{\lambda} + \frac{\lambda}{Q_{max} V_{bat}^2} (P_{elec} + P_{aux}) \frac{\partial V_{bat}}{\partial SoC} = 0 \quad (3.8)$$

L'expression de l'état adjoint est alors donnée par :

$$\lambda(t) = \lambda_0. \exp \left(\int_0^t \frac{-1}{Q_{max} V_{bat}^2} (P_{elec} + P_{aux}) \frac{\partial V_{bat}}{\partial SoC} \right) \quad (3.9)$$

La considération de l'expression complète de la tension de la batterie mène alors vers une formulation compliquée de la solution. Une complexité qui pourrait augmenter le coût de calcul de la solution. En conséquence, la tension de la batterie sera exprimée de 3 façons différentes, avec pour chaque expression une modélisation moins rigoureuse que la précédente. Le but étant de comparer les solutions issues de ces différents degrés de rigueur de modélisation en terme d'optimalité.

Formulation 1 : tension de polarisation négligée La première formulation consiste à négliger la tension de polarisation V_{pol} . La tension de la batterie s'écrit alors :

$$V_{bat} = OCV(SoC) - R_{int} \cdot I_{bat} \quad (3.10)$$

Le courant I_{bat} peut également être exprimé en fonction de SoC . Pour éliminer le courant de l'expression de la tension, il est remplacé par $\frac{P_{bat}}{V_{bat}}$. Ce qui mène à l'expression du second ordre de V_{bat} :

$$V_{bat}^2 = OCV \cdot V_{bat} - R_{int} \cdot P_{bat} \quad (3.11)$$

où $P_{bat} = P_{elect} + P_{aux}$ est la puissance sortant de la batterie. La résolution de cette équation du second ordre donne une expression de la tension de la batterie indépendante du courant :

$$V_{bat} = \frac{OCV(SoC) + \sqrt{OCV(SoC)^2 - 4R_{int}P_{bat}}}{2} \quad (3.12)$$

La deuxième racine de l'équation de second ordre n'est pas physique, car elle peut donner des tensions négatives ne correspondant pas à la réalité.

En négligeant $\frac{\partial P_{elec}}{\partial SoC}$, la dérivée partielle de la tension de la batterie par rapport à SoC est :

$$\begin{aligned} \frac{\partial V_{bat}}{\partial SoC} &= \frac{\partial OCV}{\partial SoC} \cdot \frac{\sqrt{OCV^2 - 4R_{int} \cdot P_{bat}} + OCV}{2\sqrt{OCV^2 - 4R_{int} \cdot P_{bat}}} \\ &= \frac{\partial OCV}{\partial SoC} \cdot \frac{V_{bat}}{\sqrt{OCV^2 - 4R_{int} \cdot P_{bat}}} \end{aligned} \quad (3.13)$$

L'expression de l'état adjoint dans le cas de la Formulation 1 est donc :

$$\lambda(t) = \lambda_0 \cdot \exp \left(\int_0^t \frac{-1}{Q_{max} V_{bat}} (P_{elec} + P_{aux}) \frac{\partial OCV}{\partial SoC} \cdot \frac{1}{\sqrt{OCV^2 - 4 \cdot R_{int} \cdot P_{bat}}} dt \right) \quad (3.14)$$

Formulation 2 : tension ohmique négligée La deuxième formulation consiste à négliger en plus de la tension de polarisation la chute de tension due à la résistance interne de la batterie. La tension de la batterie est alors supposée égale à sa tension à vide :

$$V_{bat} = OCV(SoC) \quad (3.15)$$

La dérivée partielle est alors :

$$\frac{\partial V_{bat}}{\partial SoC} = \frac{\partial OCV}{\partial SoC} \quad (3.16)$$

Ce qui donne l'expression de l'état adjoint dans le cas de la Formulation 2 :

$$\lambda(t) = \lambda_0 \cdot \exp \left(\int_0^t \frac{-1}{Q_{max} V_{bat}^2} (P_{elec} + P_{aux}) \frac{\partial OCV}{\partial SoC} dt \right) \quad (3.17)$$

Formulation 3 : tension constante Cette formulation consiste à considérer que la tension de la batterie est constante et égale à sa valeur nominale. On pourra constater par la suite que cette hypothèse bien que simplificatrice permettra d'obtenir quand même une solution quasi-optimale avec des calculs plus simples.

$$V_{bat} = cte \quad (3.18)$$

Cette hypothèse implique que la tension ne dépend plus de SoC .

$$\frac{\partial V_{bat}}{\partial SoC} = 0 \quad (3.19)$$

Ce qui fait que l'état adjoint est aussi constant :

$$\lambda(t) = \lambda_0. \quad (3.20)$$

Bien que cette hypothèse ne soit pas rigoureuse quant à la description de la physique de la batterie, son utilisation dans le problème de contrôle optimal peut simplifier grandement la recherche de la solution sans pour autant altérer drastiquement l'optimalité de la solution.

Les trois formulations utilisées ne décrivent pas le système avec la même précision. Les simulations dans 3.3.1 permettront d'analyser la différence entre ces trois formulations.

3.1.2 Commande de l'embrayage C_0

Le modèle commun aux deux architectures étudiées développé dans le chapitre précédent est exprimé par les équations (2.30). La différence fondamentale est que pour la Ford Focus on a une commande de l'embrayage C_0 en plus du choix de la consigne des couples. La formulation de la solution précédente est suffisante pour l'Audi A2 puisque C_0 correspond à un coefficient unitaire. Par contre, pour la Ford Focus, il reste à calculer la commande à l'embrayage. Rappelons que cette commande s'obtient selon l'équation (3.4). Afin de minimiser l'Hamiltonien par rapport à C_0 étudions $\frac{\partial H}{\partial C_0}$.

Dans les trois formulations de V_{bat} proposées, la dérivée partielle de l'Hamiltonien par rapport à C_0 s'écrit :

$$\frac{\partial H}{\partial C_0} = \lambda(t) \cdot \frac{Tq_{ice}}{\beta \cdot Q_{max} V_{bat}} \cdot \frac{\partial P_{elec}}{\partial Tq_{ema}} \quad (3.21)$$

$$= \lambda_0 \cdot \exp\left(\int_0^t \frac{\partial H}{\partial SoC} dt\right) \cdot \frac{Tq_{ice}}{\beta \cdot Q_{max} V_{bat}} \cdot \frac{\partial P_{elec}}{\partial Tq_{ema}} \quad (3.22)$$

Le terme $\frac{\partial P_{elec}}{\partial Tq_{ema}}$ désigne la dérivée partielle de la puissance électrique consommée par le moteur par rapport au couple fournit. Il est évident que la puissance consommée augmente avec le couple fournit. On peut alors affirmer que :

$$\frac{\partial P_{elec}}{\partial Tq_{ema}} > 0$$

En conséquence et puisque β , Q_{max} et V_{bat} sont des grandeurs positives, le signe de $\frac{\partial H}{\partial C_0}$ dépend de λ_0 et de Tq_{ice} . Ce dernier est le couple optimal qui sera déterminé par l'autre minimisation de l'Hamiltonien, et qu'on ne peut imposer. Par contre l'initialisation du co-état λ_0 est un paramètre qu'on doit déterminer afin de satisfaire les contraintes du problème.

Dans ce qui suit, le signe de $\frac{\partial H}{\partial C_0}$ est étudié et montre que $H(C_0)$ est toujours une fonction monotone et donc que son minimum se trouve à l'une des extrémités $C_0 = 1$ ou $C_0 = 0$.

— Si $\lambda_0 > 0$:

— Pour $Tq_{ice} > 0$: $\frac{\partial H}{\partial C_0} > 0$ l'Hamiltonien est donc croissant par rapport à C_0 .
On en déduit que

$$C_0^{opt}(t) = 0 \quad \forall t$$

— Pour $Tq_{ice} = 0$: $\frac{\partial H}{\partial C_0} = 0$ l'Hamiltonien ne dépend pas de C_0 . On en déduit que

$$C_0^{opt}(t) \in [0, 1] \quad \forall t$$

— Si $\lambda_0 < 0$:

— Pour $Tq_{ice} > 0$: $\frac{\partial H}{\partial C_0} < 0$ l'Hamiltonien est donc décroissant par rapport à C_0 .
On en déduit que

$$C_0^{opt}(t) = 1 \quad \forall t$$

— Pour $Tq_{ice} = 0$: $\frac{\partial H}{\partial C_0} = 0$ l'Hamiltonien ne dépend pas de C_0 . On en déduit que

$$C_0^{opt}(t) \in [0, 1] \quad \forall t$$

Comme le montre le tableau 3.1, si le λ_0 choisi est positif, la solution optimale consiste à ouvrir l'embrayage ($C_0 = 0$) pendant toute la phase de traction, ce qui signifie une traction complètement électrique. Cette solution n'est pas admise, car elle ne garantit pas la satisfaction de la contrainte sur l'état de charge final. La solution du problème qui satisfait la contrainte est alors avec un λ_0 négatif, ce qui donne un embrayage fermé à chaque fois que l'ICE est utilisé.

TABLE 3.1 – Commande de l'embrayage C_0 optimale en fonction du signe de λ_0

C_0^{opt}	$\lambda_0 > 0$	$\lambda_0 < 0$
$Tq_{ice} > 0$	$C_0 = 0$	$C_0 = 1$
$Tq_{ice} = 0$	$C_0^{opt} \in [0, 1]$	$C_0^{opt} \in [0, 1]$

Quand l'ICE n'est pas utilisé, le calcul ne spécifie aucune valeur de solution optimale pour C_0 , car l'Hamiltonien du problème ne dépend plus de C_0 . Cependant, le modèle développé du problème ne prend pas en compte, entre autres, la consommation de l'ICE quand le moteur est démarré sans être utilisé. Afin d'éviter le coût supplémentaire correspondant, l'ICE est arrêté quand $Tq_{ice} = 0$. Il est alors nécessaire d'ouvrir l'embrayage pour pouvoir arrêter le moteur. La commande optimale de l'embrayage au cas où $Tq_{ice} = 0$ est alors $C_0^{opt} = 0$.

Notons que les dynamiques négligées ici dans le modèle d'optimisation seront prises en comptes dans le modèle de simulation plus complet AMESim sur lequel notre méthode sera testée dans la section 3.3.2.

La commande optimale de l'embrayage est alors :

$$\begin{cases} C_0 = 0 & \text{si } Tq_{ice} = 0 \\ C_0 = 1 & \text{si } Tq_{ice} > 0 \end{cases}$$

En conclusion, la solution optimale est le couple qui minimise l'Hamiltonien à chaque instant. L'Hamiltonien est un critère instantané à minimiser et qui permet indirectement de résoudre le problème de contrôle optimal de l'*Energy management*. Le tableau 3.2 résume les solutions littérales induites par le PMP pour chacune des trois formulations de la tension de la batterie utilisées. Ces solutions ont été formulées en relaxant les contraintes instantanées sur *SoC* décrivant les limitations de l'état de charge. L'influence du *SoC* sur la puissance

TABLE 3.2 – Commande optimale du problème de l'Energy management en fonction de la formulation utilisée

V_{bat}	Commande Optimale
Formulation 1 OCV $-R_{int}I_{bat}$	$Tq_{ice}^{opt}(t) = \min_{Tq_{ice}} H(SoC, Tq_{ice}, \lambda)$ $H(SoC, Tq_{ice}, \lambda) = P_{fuel}(Tq_{ice}, N_{clu}) - \frac{\lambda}{Q_{max}} \frac{P_{elec}(\frac{1}{\beta}(Tq_{clu} - C_0 \cdot Tq_{ice}), \beta \cdot N_{clu}) + P_{aux}}{V_{bat}}$ $\lambda(t) = \lambda_0 \cdot \exp(\int_0^t \frac{-1}{Q_{max} V_{bat}} (P_{elec} + P_{aux}) \frac{\partial OCV}{\partial SoC} \cdot \frac{1}{\sqrt{OCV^2 - 4 \cdot R_{int} \cdot P_{bat}}} dt)$ $C_0^{opt}(t) = 1 \text{ si } Tq_{ice}^{opt}(t) > 0$ $C_0^{opt}(t) = 0 \text{ si } Tq_{ice}^{opt}(t) = 0$
Formulation 2 $OCV(SOC)$	$Tq_{ice}^{opt}(t) = \min_{Tq_{ice}} H(SoC, Tq_{ice}, \lambda)$ $H(SoC, Tq_{ice}, \lambda) = P_{fuel}(Tq_{ice}, N_{clu}) - \frac{\lambda}{Q_{max}} \frac{P_{elec}(\frac{1}{\beta}(Tq_{clu} - C_0 \cdot Tq_{ice}), \beta \cdot N_{clu}) + P_{aux}}{V_{bat}}$ $\lambda(t) = \lambda_0 \cdot \exp(\int_0^t \frac{-1}{Q_{max} V_{bat}^2} (P_{elec} + P_{aux}) \frac{\partial OCV}{\partial SoC} dt)$ $C_0^{opt}(t) = 1 \text{ si } Tq_{ice}^{opt}(t) > 0$ $C_0^{opt}(t) = 0 \text{ si } Tq_{ice}^{opt}(t) = 0$
Formulation 3 Constante	$Tq_{ice}^{opt}(t) = \min_{Tq_{ice}} H(SoC, Tq_{ice}, \lambda)$ $H(SoC, Tq_{ice}, \lambda) = P_{fuel}(Tq_{ice}, N_{clu}) - \frac{\lambda}{Q_{max}} \frac{P_{elec}(\frac{1}{\beta}(Tq_{clu} - C_0 \cdot Tq_{ice}), \beta \cdot N_{clu}) + P_{aux}}{V_{bat}}$ $\lambda(t) = \lambda_0$ $C_0^{opt}(t) = 1 \text{ si } Tq_{ice}^{opt}(t) > 0$ $C_0^{opt}(t) = 0 \text{ si } Tq_{ice}^{opt}(t) = 0$

électrique de l'EMA est aussi négligée dans l'expression de l'Hamiltonien et les simulations montrent également l'impact de ses deux hypothèses. Ceci étant dit, ces solutions ne sont pas encore complètement définies car il reste à initialiser l'état adjoint λ , bien qu'on ait réussi à déterminer le signe de λ_0 . La partie suivante discute le sens de l'état adjoint ainsi que la méthode algorithmique qui servira à l'initialiser.

3.1.3 Initialisation du co-état : Bases théoriques de l'algorithme de tirs

En général, l'initialisation de l'état adjoint dans la résolution des problèmes de contrôle optimal se fait en intégrant les équations dynamiques du système de façon à retrouver un état final égal à celui imposé par la contrainte, en ce qui constitue la méthode indirecte de tirs (1.2.1.2). Dans le cas du problème (3.1) de l'*Energy management* formulé, l'intégration de l'équation dynamique du système donne :

$$SoC(T) = SoC(0) + \int_0^T \frac{-1}{Q_{max}} \frac{P_{elec}(\frac{1}{\beta}(Tq_{clu} - C_0 \cdot Tq_{ice}^{opt}(\lambda_0)), \beta \cdot N_{clu}) + P_{aux}}{V_{bat}} .dt \quad (3.23)$$

où $Tq_{ice}^{opt}(\lambda_0)$ est le couple obtenu en minimisant l'Hamiltonien correspondant l'initialisation du co-état λ_0 .

Ainsi, il s'avère que la valeur de λ_0 détermine la valeur de l'état de charge final $SoC(T)$. Pour vérifier la contrainte $SoC(T) = SoC_f$, l'état adjoint initial doit vérifier l'équation :

$$SoC_f = SoC(0) + \int_0^T \frac{-1}{Q_{max}} \frac{P_{elec}(\frac{1}{\beta}(Tq_{clu} - C_0 \cdot Tq_{ice}^{opt}(\lambda_0)), \beta \cdot N_{clu}) + P_{aux}}{V_{bat}} .dt \quad (3.24)$$

Compléter la résolution du problème de contrôle optimal consiste alors à résoudre l'équation (3.24) en λ_0 . Dans le cas présent, la résolution analytique de cette équation est inaccessible. D'abord parce que la fonction P_{elect} est une cartographie de points, et n'est pas sous forme analytique. Ensuite, l'équation met en jeu des expressions non-linéaires qui rendent la résolution de l'équation d'autant plus difficile.

La résolution de l'équation (3.24) est faite sous la forme d'un problème de minimisation ou de recherche de zéro. En notant la fonction de tirs :

$$f(\lambda_0) = SoC(0) + \int_0^T \frac{-1}{Q_{max}} \frac{P_{elec}(\frac{1}{\beta}(Tq_{clu} - C_0 \cdot Tq_{ice}^{opt}(\lambda_0)), \beta \cdot N_{clu}) + P_{aux}}{V_{bat}} .dt \quad (3.25)$$

La recherche de l'initialisation de l'état adjoint est matérialisée par la résolution de l'équation non-linéaire en λ_0 :

$$f(\lambda_0) = SoC_f$$

Qui peut être réalisée en minimisant l'écart entre $f(\lambda_0)$ et SoC_f :

$$\lambda_0^{opt} = \min_{\lambda_0} |f(\lambda_0) - SoC_f| \quad (3.26)$$

Cette équation est impossible à résoudre analytiquement, à cause de la nature de la fonction de tirs f . Il reste alors à déterminer un algorithme de résolution.

La signification de l'état adjoint donne une indication sur la monotonie de f et sur le choix d'un algorithme judicieux pour l'algorithme de tirs. Les solutions exposées dans le tableau 3.2 donnent la consigne de couple optimale comme étant le couple minimisant un critère instantané (l'Hamiltonien). Ce critère instantané s'écrit comme la somme pondérée des deux puissances, celle du moteur à combustion interne, et celle du moteur électrique.

$$H = P_{fuel}(T_{q_{ice}}, N_{clu}) - \frac{\lambda}{Q_{max}} \frac{P_{elec}(\frac{1}{\beta}(T_{q_{clu}} - C_0.T_{q_{ice}}), \beta.N_{clu}) + P_{aux}}{V_{bat}} \quad (3.27)$$

$$= P_{fuel} + \alpha.P_{elec} + \gamma \quad (3.28)$$

où $\alpha = -\frac{\lambda}{Q_{max}V_{bat}}$ est le coefficient de pondération, $\gamma = \frac{-\lambda.P_{aux}}{Q_{max}V_{bat}}$ étant un terme constant par rapport à $T_{q_{ice}}$ est donc neutre par rapport à la minimisation de l'Hamiltonien. Le couple optimal s'obtient en minimisant l'expression :

$$P_{fuel} + \alpha.P_{elec} \quad (3.29)$$

Ce résultat confirme une certaine intuition, puisqu'on cherche à répartir l'énergie entre les deux moteurs, il faut trouver un compromis d'utilisation garantissant l'état de charge de la batterie souhaité. Ce compromis est alors représenté par le coefficient de pondération α (et donc indirectement par le co-état du problème de contrôle optimal λ). L'augmentation de α donne plus de poids au terme électrique dans la minimisation du critère pondéré, et vice versa. On peut alors dire que, puisque $Q_{max}V_{bat} > 0$, l'augmentation de $-\lambda$ donne plus de poids au terme électrique dans la minimisation du critère pondéré, et vice versa. En conséquence, l'augmentation de $-\lambda$ mène vers un $T_{q_{ice}}^{opt}$ plus élevé, de façon à moins utiliser la puissance électrique. Il en découle que la fonction $T_{q_{ice}}^{opt}(\lambda_0)$ est décroissante.

Cette dernière conclusion est basée sur la signification physique du co-état dans la minimisation de l'Hamiltonien. En se basant sur cette conclusion ($T_{q_{ice}}^{opt}(\lambda_0)$ est décroissante), on peut étudier la monotonie de la fonction $f(\lambda_0)$ à l'aide de son expression donnée par (3.25).

L'expression $\frac{1}{\beta}(T_{q_{clu}} - C_0.T_{q_{ice}}^{opt}(\lambda_0))$ est croissante en λ_0 et puisque la puissance électrique est croissante en fonction du couple, l'expression :

$$-1 \frac{P_{elec}(\frac{1}{\beta}(T_{q_{clu}} - C_0.T_{q_{ice}}^{opt}(\lambda_0)), \beta.N_{clu}) + P_{aux}}{Q_{max}V_{bat}}$$

est décroissante en λ_0 . En conclusion, f étant une somme continue de fonctions décroissantes,

est une fonction décroissante :

$$\frac{\partial f}{\partial \lambda_0} < 0 \quad \forall \lambda_0$$

Rappelons que $f(\lambda_0)$ représente l'état de charge final correspondant à l'utilisation de λ_0 dans la minimisation de l'Hamiltonien. La conclusion précédente implique que $f(-\lambda_0)$ est croissante et donc que $f(\alpha)$ est croissante ($\alpha = -\frac{\lambda}{Q_{max} V_{bat}}$). Comme le montre l'équation (3.29), un coefficient de pondération de la puissance électrique plus grand mène à un état de charge final plus élevé.

Notons $\alpha_0 = \alpha(0)$. Pour confirmer les hypothèses de monotonie de $f(\alpha_0)$ (ce qui est équivalent à $f(\lambda_0)$), des simulations sur différents trajets ont été réalisées. En balayant un domaine de variation de $\alpha_0 \in [1, 5]$, $f(\alpha_0)$ (ce qui correspond à l'état de charge final) est calculé pour les deux véhicules étudiés. Les trajets utilisés sont, le cycle NEDC, le cycle WLTC et le cycle RDE95. (Annexe A).

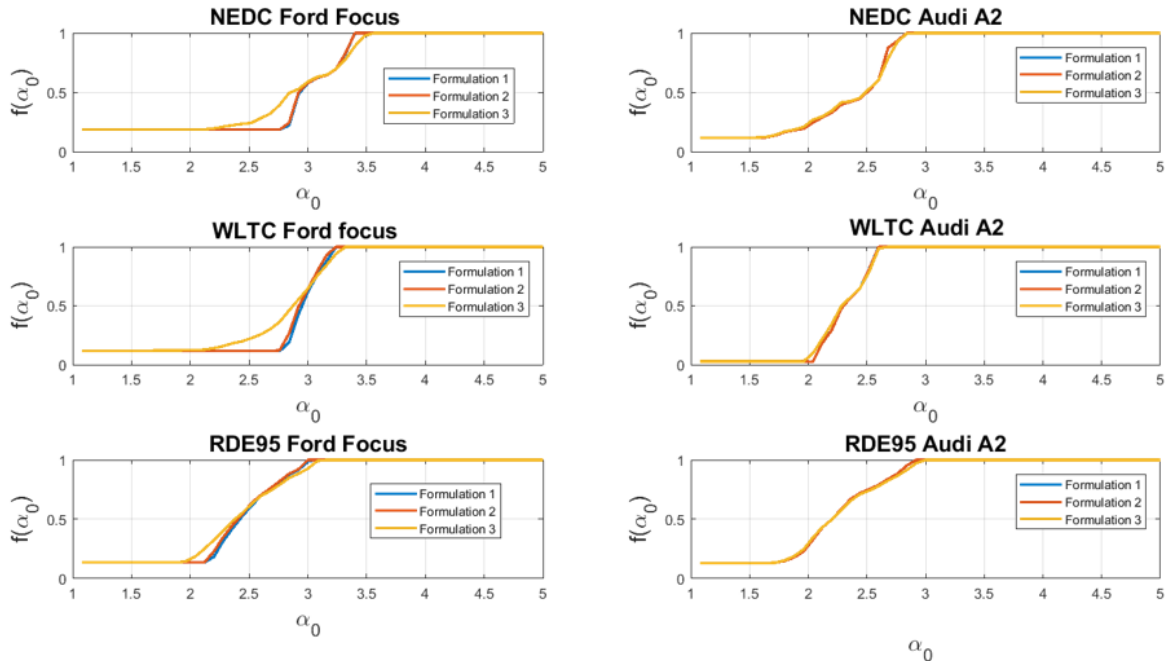


FIGURE 3.2 – Monotonie de f : Variation de l'état de charge final en fonction du co-état initial sur les trajets NEDC, WLTC et RDE95 avec la Ford Focus 48V et la Audi A2

Pour chacune des hypothèses faites sur la tension de la batterie, on retrouve la monotonie croissante de $f(\alpha_0)$, pour les trois trajets simulés et pour les deux véhicules (Figure 3.2). Notons que le α_0 donnant l'état de charge final à 50% par exemple ici, est différent pour chacune des trois formulations de V_{bat} . Notons aussi, pour tous les cas étudiés, que $f(\alpha_0)$ prend toutes les valeurs possibles dans l'intervalle $\alpha_0 \in [1.5, 3.5]$ comme le montre la Figure 3.2. La recherche de α_0 (l'initialisation du co-état) peut se faire dans cet intervalle pour les cas étudiés. α est un coefficient de pondération de la puissance électrique dans la minimisation de l'Hamiltonien, et sachant que le rendement de l'EMA est plus ou moins 3 fois plus grand

que celui de l'ICE, il paraît évident que les valeurs que prend α durant un trajet permettant de maintenir l'état de charge à sa valeur initiale se trouve autour de 3. Ainsi, en se basant sur les résultats exposés dans la Figure 3.2 et afin de pouvoir atteindre n'importe quelle valeur de SoC_f , l'intervalle de recherche de α_0 est choisit :

$$\alpha_0^{opt} \in [1, 4]$$

La recherche de λ_0 est équivalente à la recherche de α_0 (car $\alpha = -\frac{\lambda}{Q_{max}V_{bat}}$). Le rôle que joue α comme coefficient de pondération entre les deux puissances P_{elec} et P_{fuel} donne une idée plus ou moins précise sur l'ordre de grandeur des valeurs de α . Pour cette raison, la recherche d'initialisation optimale de l'état adjoint du problème sera faite en recherchant la valeur de α_0^{opt} . Dans la suite, initialisation de l'état adjoint et recherche de α_0^{opt} seront confondues.

Le problème de l'initialisation de l'état adjoint du problème de l'*Energy management* est alors équivalent à un problème de recherche de zéro d'une fonction non-linéaire monotone, en l'occurrence croissante. Pour résoudre le problème de la recherche du zéro d'une fonction non-linéaire croissante d'une seule variable, nous avons choisi un algorithme de dichotomie. En effet, cet algorithme ne nécessite pas le calcul d'une dérivée, il combine alors simplicité et efficacité d'implémentation et garantie de résultat.

Après la formulation des solutions optimales dans le tableau 3.2, puis la détermination d'un algorithme de dichotomie permettant de paramétrer judicieusement cette solution, la solution du problème de contrôle optimal de l'*Energy management* est complètement définie. Dans la partie suivante, le problème est remis dans son contexte automobile, et l'algorithme mis en jeu pour matérialiser cette solution est développé.

3.2 Structure algorithmique du *PMP Energy management*

Les équations développées lors de la partie précédente suggèrent une solution algorithmique à deux niveaux. D'abord, le premier algorithme se doit d'assurer la paramétrisation adéquate de l'Hamiltonien pour atteindre l'état de charge final souhaité (initialisation du co-état). En se basant sur l'analyse de monotonie de la fonction de tir f qui lie une initialisation d'état adjoint à un état de charge final, il s'est avéré qu'un algorithme de dichotomie est le plus adapté pour l'algorithme de tirs. Ensuite, un autre algorithme se doit d'assurer que les consignes de couples choisies minimisent l'Hamiltonien du problème. Cette minimisation est faisable sans recourir à un quelconque algorithme d'optimisation, puisque la fonction à minimiser est entièrement connue analytiquement.

3.2.1 Méthode indirecte de tirs

La méthode indirecte de tirs a pour but de trouver le co-état initial qui permet d'obtenir l'état de charge final visé, pour un trajet donné. Il doit alors avoir comme paramètres les prédictions des demandes de couples et de vitesses ($T_{q_{clu}}, N_{clu}$). En effet, l'algorithme de tirs fera des évaluations de la fonction f . Les demandes ($T_{q_{clu}}, N_{clu}$) qui définissent le trajet sont utilisées dans la définition de f comme le montre l'équation (3.25).

La méthode indirecte de tirs va donc évaluer la fonction f sur un intervalle de $\alpha_0 \in [1, 4]$. Il sera guidé par un algorithme de dichotomie pour trouver la valeur optimale. L'algorithme de dichotomie définit de manière itérative des intervalles qui encadrent cette valeur, en évaluant à chaque fois la fonction f au milieu de l'intervalle. Si $f(\alpha_0) - SoC_f$ est négatif, le nouvel intervalle est la partie supérieure de l'intervalle précédent, et si $f(\alpha_0) - SoC_f$ est positif, le nouvel intervalle est la partie inférieure de l'intervalle précédent (Figure 3.3). L'algorithme s'arrête à partir du moment où $f(\alpha_0)$ est égal à SoC_f à ϵ_{SoC} près. ϵ_{SoC} étant la marge d'erreur tolérée.

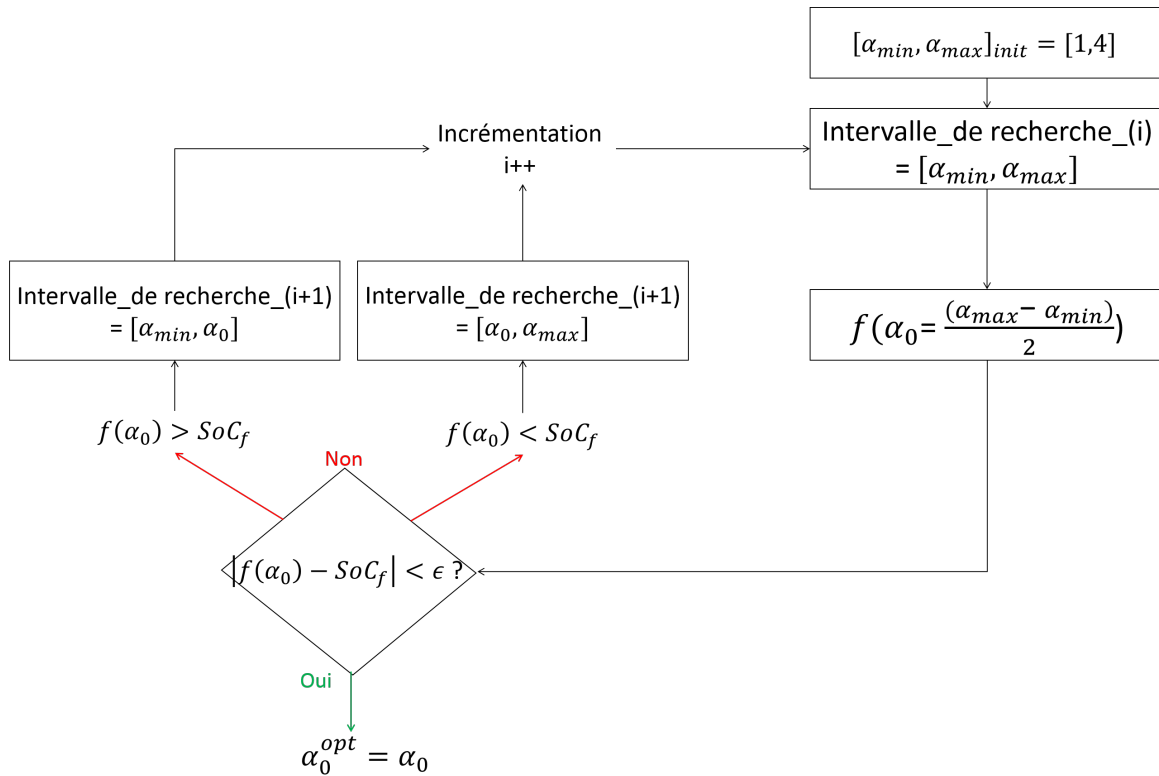


FIGURE 3.3 – Schéma de l'algorithme de tirs avec dichotomie

Le calcul de $f(\alpha_0)$ correspond à l'intégration temporelle du système pour calculer l'état de charge final. En d'autres termes, ce calcul correspond à une simulation des dynamiques électriques du véhicule nécessaires au calcul de l'état de charge final. Cette simulation est effectuée sur le trajet prédit, caractérisé par les prédictions des demandes de couples et vitesses ($T_{q_{clu}}, N_{clu}$) (Figure 3.4). Les équations dynamiques du système sont intégrées numérique-

ment, après avoir été discrétisées au premier ordre.

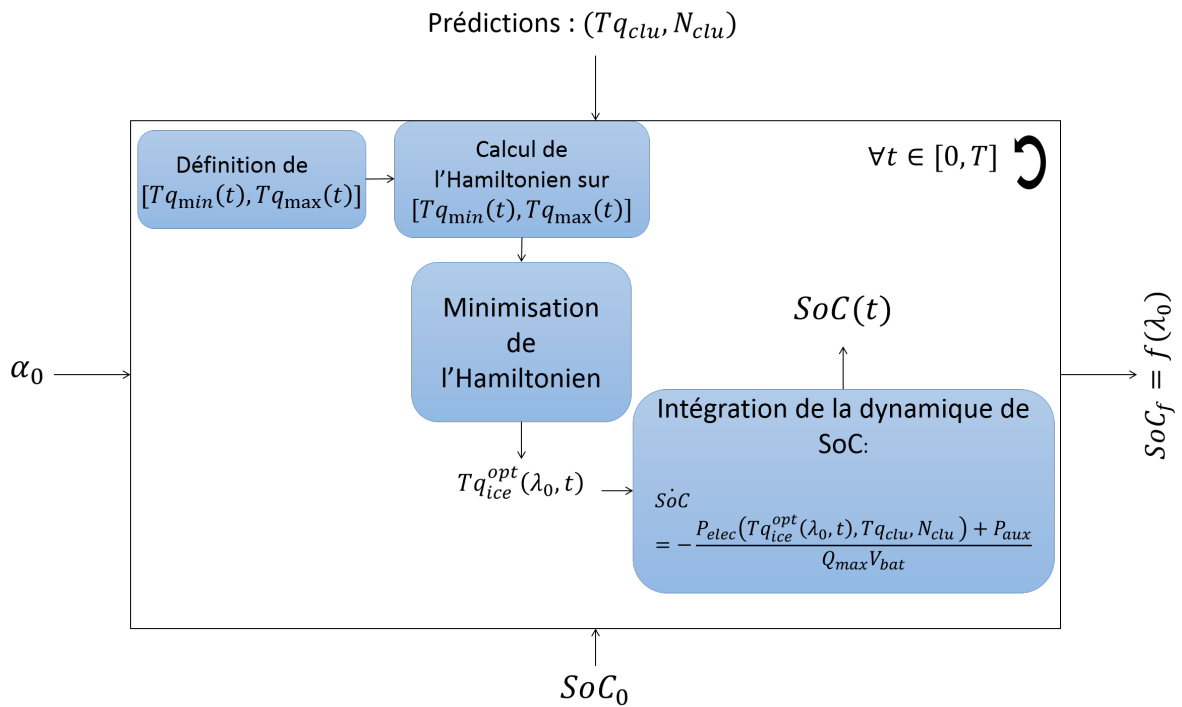


FIGURE 3.4 – Fonction f : Calcul de l'état de charge final en fonction de l'initialisation du co-état, et des prédictions.

3.2.2 Structure de l'algorithme en temps-réel

Les algorithmes décrits dans la partie précédente recherchent l'état adjoint initial pour une prédiction donnée. Une fois ce calcul établi, son résultat est utilisé pour (re)paramétrer l'Hamiltonien en temps-réel. La méthode indirecte de tirs est donc enclenchée à chaque nouvelle prédiction, tandis que la minimisation de l'Hamiltonien est une tâche 'à chaque instant'. La question qui se pose est alors celle de la durée au bout de laquelle on sonde une prédiction. Cette durée est appelée ici *Horizon de prédiction* que l'on notera T . En notant T_s la période d'échantillonnage des calculs embarqués, notons p le nombre d'échantillons dans un horizon de prédiction $T = p.T_s$. L'influence de ce paramètre p définissant l'horizon de prédiction sera discutée dans la fin du chapitre.

Contrairement à notre algorithme de tirs exposé dans la partie précédente qui utilise les prédictions des demandes du conducteur et les modèles des dynamiques du véhicule pour calculer l'Hamiltonien, la minimisation en temps-réel se fait évidemment en utilisant les valeurs réelles des états du véhicule et des demandes du conducteur, évoluant en temps-réel.

Au début de chaque horizon de prédiction, la prédiction (Tq_{clu}, N_{clu}) caractérisant le futur trajet sur les $T = p.T_s$ secondes suivantes est recueillie par le calculateur et est utilisée dans

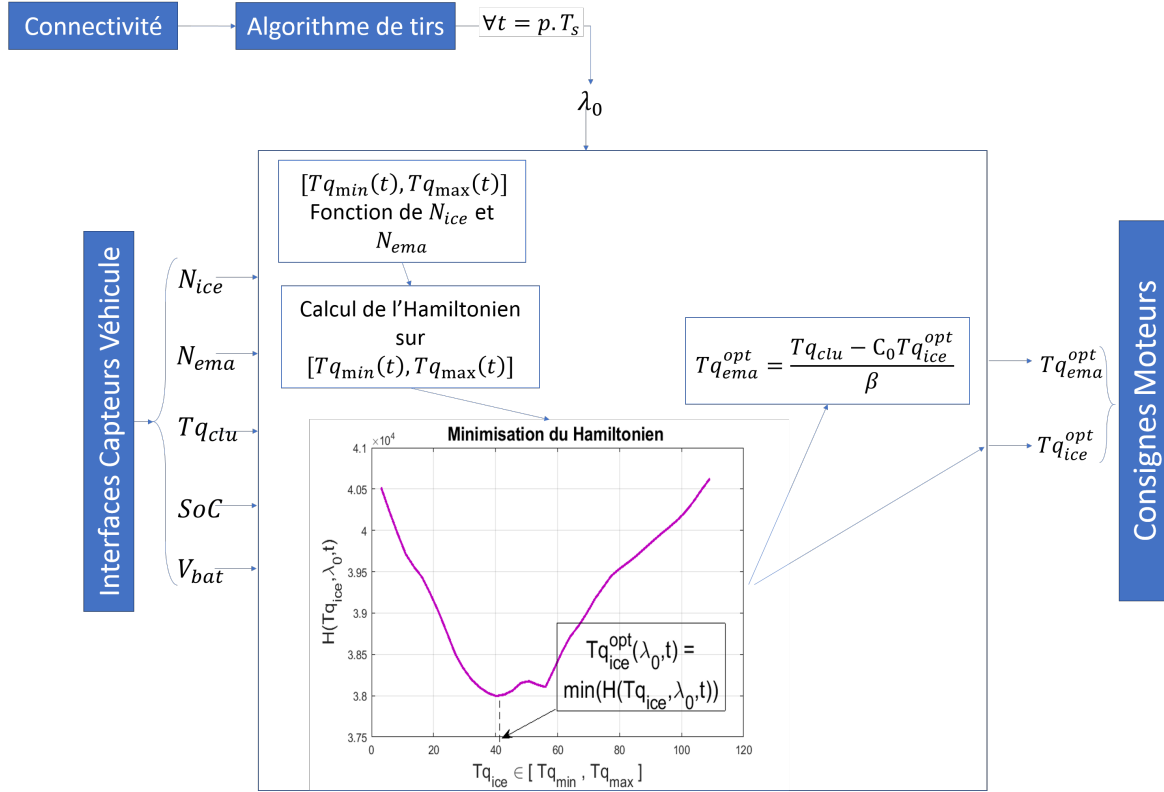


FIGURE 3.5 – Minimisation de l’Hamiltonien en temps réel en fonction des états réels du système et de l’initialisation du co-état.

l’algorithme de tirs du PMP Energy management. Pendant le premier pas de calcul de durée T_s , α_0^{opt} est calculée de façon à garantir la contrainte finale $SoC(T = pT_s) = SoC_f$. Cette valeur est ensuite utilisée par la minimisation de l’Hamiltonien pendant tous les pas de calcul suivants et jusqu’à la fin de l’horizon de prédiction actuel. Dans le cadre de l’hypothèse de ce chapitre qui donne des prédictions complètement viables, l’état de charge de la batterie à la fin de chaque horizon de prédiction doit être égal à l’état de charge visé au départ. Une fois arrivé à la fin de l’horizon de prédiction, de nouvelles prédictions sont recueillies pour paramétrer à nouveau le problème de contrôle optimal. Un nouvel α_0^{opt} est calculé, l’Hamiltonien re-paramétré et ainsi de suite... (Figure 3.6).

L’algorithme du *PMP Energy management* exposé dans cette section se base sur les équations issues du contrôle optimal synthétisées en début de ce chapitre, et qui utilisent le PMP. En conséquence, on s’attend théoriquement à retrouver la solution optimale du problème (3.1). Néanmoins, ces solutions se sont basées sur des hypothèses telles que la relaxation de la contraintes sur les limites de SoC , ou les différentes formulations de la tension de la batterie. Dans la partie suivante, l’algorithme du PMP Energy management développé dans cette section va être utilisé dans des simulations de différents trajets, et avec les deux véhicules étudiés dans le chapitre 2. Les solutions issues des différentes formulations et paramétrages seront comparées afin d’étudier l’influence du modèle de la batterie et de l’horizon de prédiction.

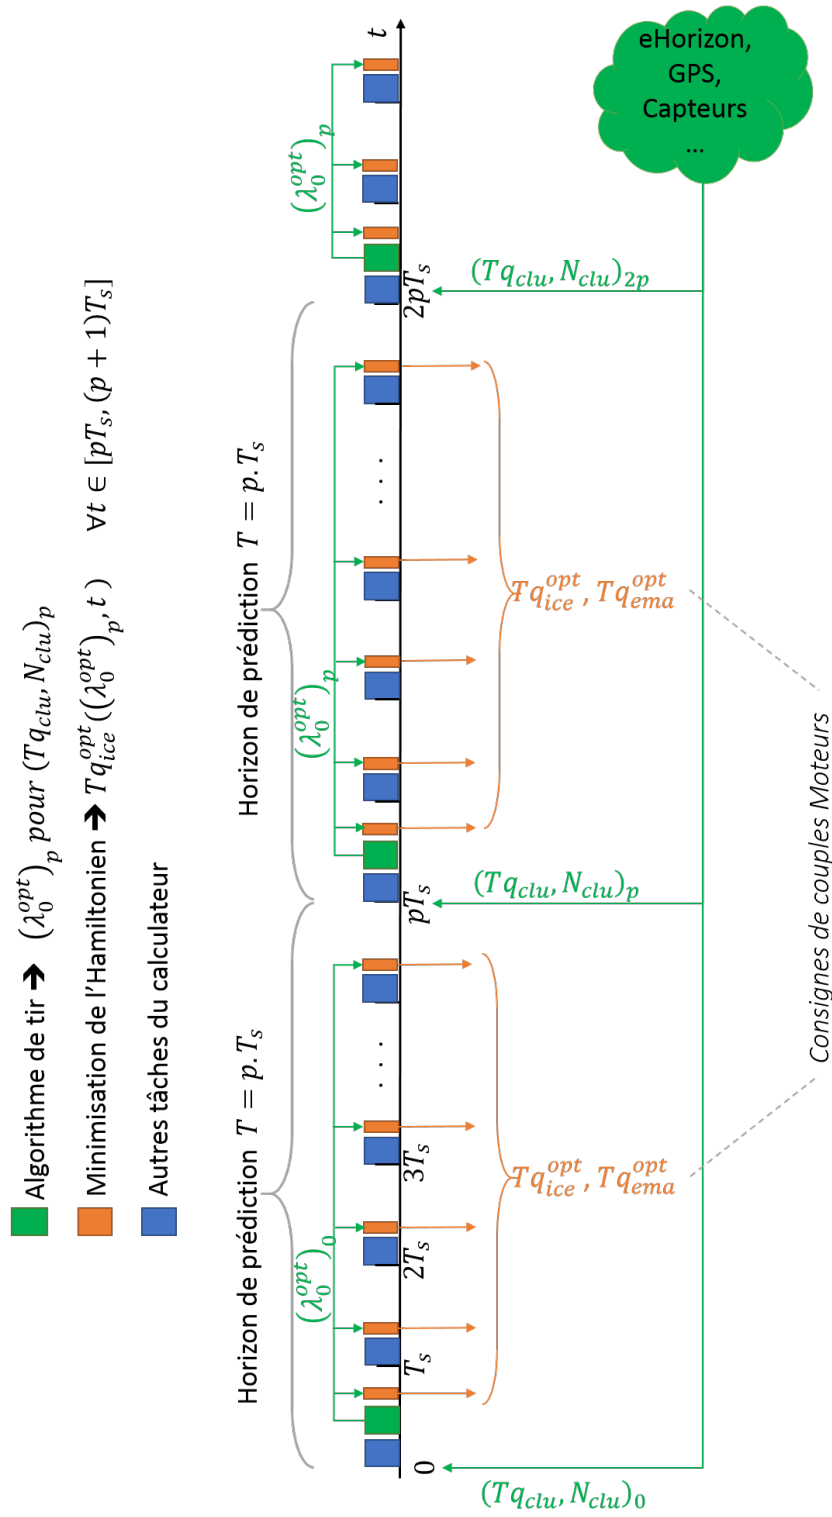


FIGURE 3.6 – Séquencement des tâches du PMP Energy management embarqué.

3.3 Évaluation du *PMP Energy Management* par simulation

La méthode développée a adopté certaines hypothèses qui s'éloignent du modèle complet théorique de départ (3.1). Dans une première partie la méthode du PMP Energy management est comparée à un algorithme de DP qui utilise les équations complètes sans simplification. La solution de la DP étant considérée comme une solution référence, ces simulations permettront d'évaluer la méthode en terme de performance, ainsi que d'analyser l'influence des hypothèses et des différentes formulations de V_{bat} adoptées. La deuxième partie des simulations sera réalisée avec le modèle de véhicule complet (AMESim), contenant toutes les dynamiques thermiques, électriques et mécaniques du véhicule, fourni par les équipes de Continental Automotive. Le *PMP Energy management* sera alors implémenté sur ce modèle et comparé à une méthode à base de règles (CostBased) développée par les ingénieurs experts. La méthode sera alors testée dans des conditions plus proches d'un environnement de véhicule réel. Les résultats pourront ainsi mener à une analyse qualitative de la solution optimale.

3.3.1 Simulation sur le modèle de référence

Le modèle de véhicule utilisé pour les simulations est évidemment le modèle complet sans simplifications. Les simulations Matlab sont réalisées avec les paramètres indiqués dans le tableau 3.3.

Dans un premier temps les simulations sont effectuées avec l'horizon de prédiction le plus grand possible, c'est-à-dire égal à la longueur du cycle simulé. L'état de charge final et initial de la batterie sont égaux et fixés à 50%. Les cycles simulés sont des cycles d'homologation (Annexe A) :

- Le cycle NEDC
- Le cycle WLTC
- Le cycle RDE95
- Le cycle JC08
- Le cycle Artemis

TABLE 3.3 – Paramètres du *PMP Energy management* lors des simulations sur le modèle de référence.

SoC_0	50%
SoC_f	50%
ϵ_{SoC}	0.5%
$[\alpha_{min}\alpha_{max}]_{init}$	[1, 4]
T_s	100ms
T (Horizon de prédiction)	Longueur du cycle étudié

3.3.1.1 Résultats des simulations

Un algorithme de programmation dynamique se basant sur les équations dans 1.2.1.2 est utilisé pour calculer la solution référence. Les résultats exposés dans le Tableau 3.4 montrent que la consommation obtenue par la programmation dynamique est inférieure où égale aux consommations obtenues par notre algorithme basé sur le PMP. Ceci étant dit, l'écart en consommation entre les deux méthodes est souvent nul. Pour la Ford Focus, on arrive à avoir la même consommation pour les cycles RDE95, JC08 et Artemis, entre les algorithmes de DP et PMP Energy management. Dans les cycles NEDC et WLTC, le PMP Energy management consomme 1g de plus avec la Formulation 1. Pour l'Audi A2 l'utilisation de la formulation 1 de notre méthode permet dans tous les cas d'obtenir la même consommation que la DP. Il est à noter que le temps de calcul moyen des trois formulations du PMP est autour de 1min. Évidemment, la DP prend beaucoup plus de temps, avec un temps de calcul avoisinant les 3h en moyenne.

TABLE 3.4 – Résultats de consommation en grammes avec le modèle de référence pour les 3 formulations du *PMP Energy management* en comparaison avec un algorithme de DP.

Ford Focus GTC2 48V					
	NEDC	WLTC	RDE95	JC08	Artemis
PMP Formulation 1	277g	854g	508g	236g	1314g
PMP Formulation 2	278g	854g	508g	237g	1315g
PMP Formulation 3	278g	855g	508g	237g	1316g
Programmation dynamique	276g	853g	508g	236g	1314
Audi A2 Hybrid 330V					
	NEDC	WLTC	RDE95	JC08	Artemis
PMP Formulation 1	225g	718g	446g	180g	1294g
PMP Formulation 2	225g	720g	446g	180g	1294g
PMP Formulation 3	225g	721g	447g	181g	1294g
Programmation dynamique	225g	718g	446g	180g	1294

3.3.1.2 Influence de la formulation de V_{bat}

L'écart des consommations entre les trois différentes formulations de la tension batterie reste très réduit. En termes de consommation, la formulation 1 est la plus efficace, puis la formulation 2 et la formulation 3 donne le plus de consommation. Les différences de consom-

mation entre ces différentes formulations restent toutes inférieures à 1% et ne sont pas significatives. Afin de comprendre la raison de la similitude entre ces différentes formulations, analysons l'expression de l'état adjoint :

$$\lambda(t) = \lambda_0 \cdot \exp\left(\int_0^t \frac{\partial H}{\partial SoC}\right) \quad (3.30)$$

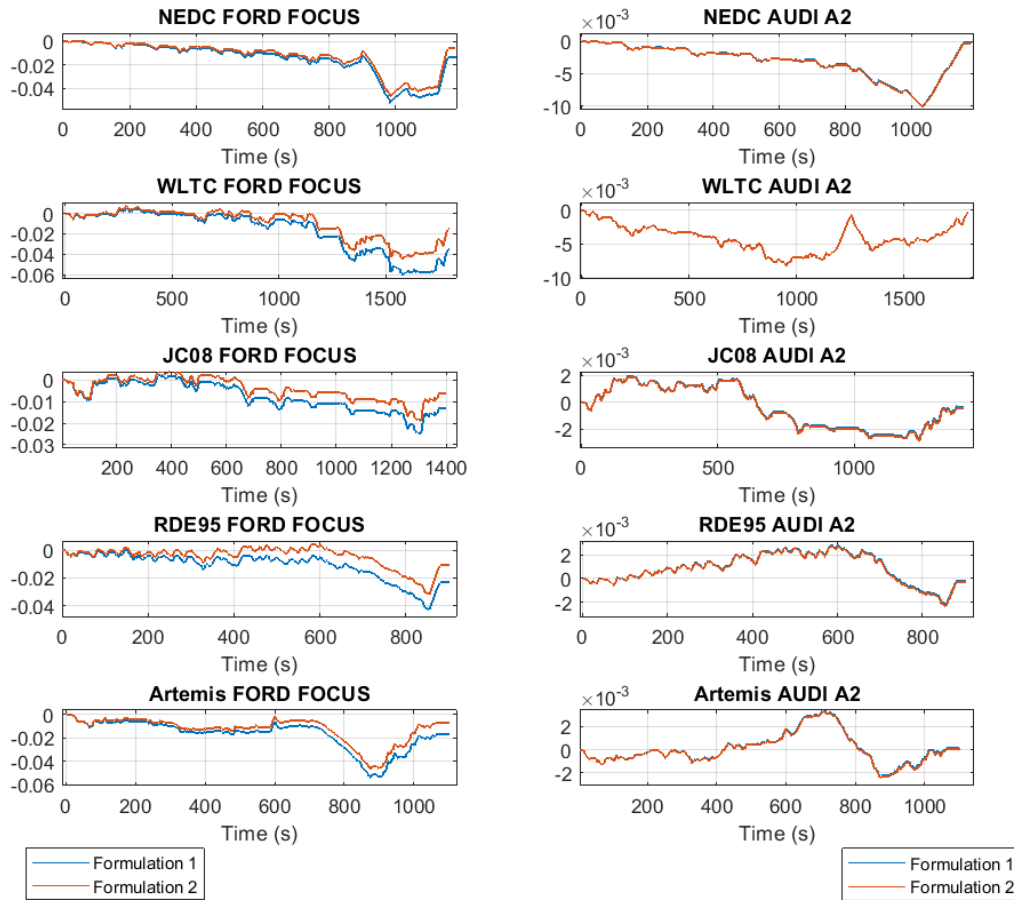


FIGURE 3.7 – Variation de $\int \frac{\partial H}{\partial SoC}$ le long des trajets simulés, pour les deux formulations à état adjoint variable

L'état adjoint est le produit de sa valeur initiale par l'exponentielle de $\int_0^t \frac{\partial H}{\partial SoC}$. Cette valeur dépend de la formulation utilisée (3.2). La Figure 3.7 illustre les variations de cette valeur.

Pour la Ford Focus GTC2, la valeur de $\int_0^t \frac{\partial H}{\partial SoC}$ dans tous les cas simulés varie entre un maximum de 0.05 et un minimum de -0.06 . Pour l'Audi A2, l'écart par rapport à 0 est encore

plus petit et est au plus de 0.01. Il est alors acceptable d'écrire dans ce cas :

$$\int_0^t \frac{\partial H}{\partial SoC} \approx 0$$

et donc que :

$$\lambda(t) \approx \lambda_0$$

Les différences dans la valeur de l'état adjoint entre les formulations ne sont pas assez significatives pour changer le minimum de l'Hamiltonien. En d'autres termes, une formulation précise des dynamiques de la batterie, mène à une solution pratiquement équivalente à celle donnée par la formulation 3.

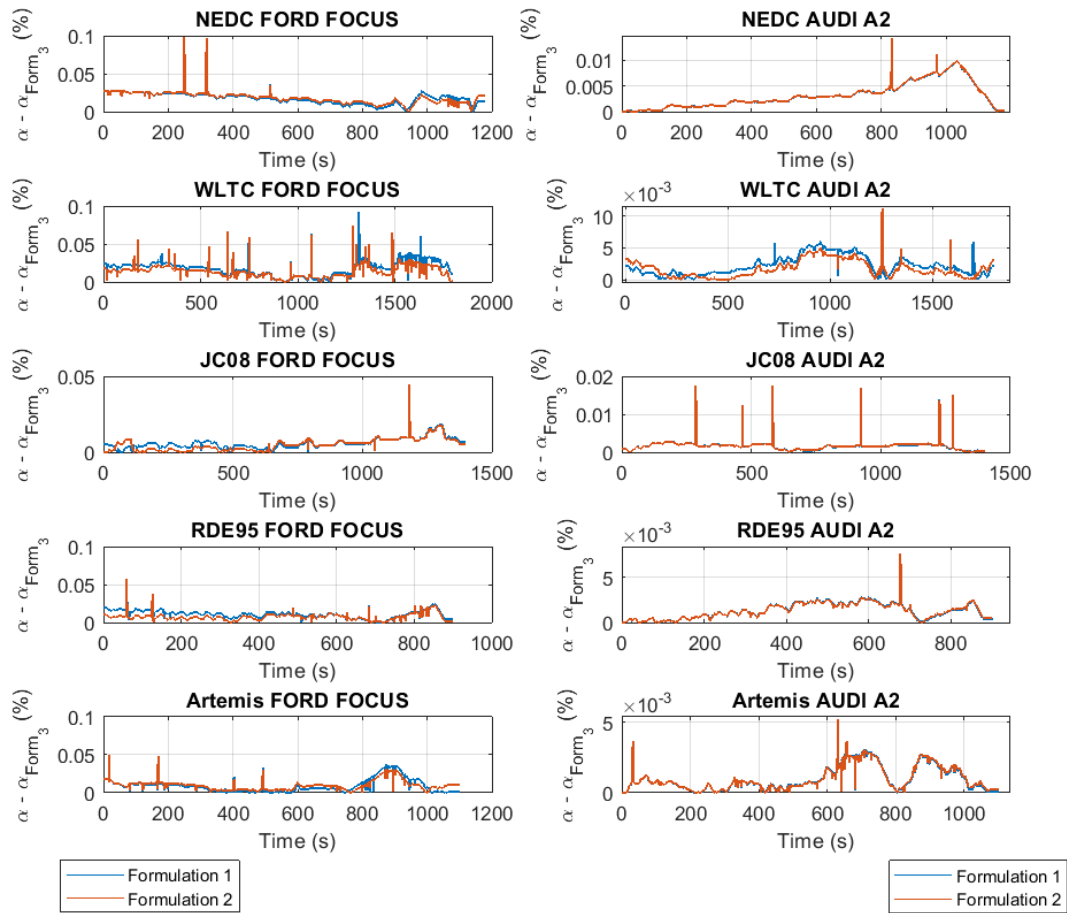


FIGURE 3.8 – Variations des différences des coefficients de pondération de l'Hamiltonien entre les formulations 1, 2 et la formulation 3

A noter qu'une batterie avec une énergie maximale plus élevée ($Q_{max} \cdot V_{bat}$) donnerait une variation encore plus petite de $\int_0^t \frac{\partial H}{\partial SoC}$ et donc moins de différence entre les formulations.

Ce qui est bien illustré dans la Figure 3.7. Les différences entre les formulations sont moins importantes pour l' Audi A2 par rapport à la Ford Focus, car en effet on a bien :

$$(Q_{max} \cdot V_{bat})_{FordFocus} = 480Wh < (Q_{max} \cdot V_{bat})_{AudiA2} = 2.31kWh$$

Inversement, une batterie avec une énergie plus petite, donnera des variations plus importantes de l'état adjoint et les différences de formulations deviendront plus importantes en terme de consommation de carburant.

Effectivement, l'expression :

$$\frac{\partial H}{\partial SoC} = \frac{1}{Q_{max} V_{bat}} I_{bat} \frac{\partial V_{bat}}{\partial SoC} \quad (3.31)$$

montre que plus l'énergie de la batterie est grande, plus le terme $\frac{\partial H}{\partial SoC}$ tend vers 0, et donc plus l'état adjoint tend vers une valeur constante.

La Figure 3.8 illustre l'évolution de la différence des coefficients de pondération α des formulations 1 et 2 par rapport à la formulation 3, sur chacun des cycles simulés. Pour la Ford Focus les différences sont de l'ordre de 0.1% alors que pour l'Audi A2 les différences sont encore plus négligeables et de l'ordre de 0.01%. La Figure 3.9 illustre la moyenne de α et son écart type pour chacune des trois formulations sur les différents trajets. Les valeurs moyennes sont identiques pour les trois formulations pour l'Audi A2. Elles le sont aussi pour la Ford Focus à 1% près sur les trajets JC08 et le NEDC. A noter que toutes ces valeurs sont comprises dans l'intervalle [2, 3]. L'écart type est de l'ordre de 0.01 pour les trois formulations sur la Ford Focus. Il est de l'ordre de 0.001 sur l'Audi A2.

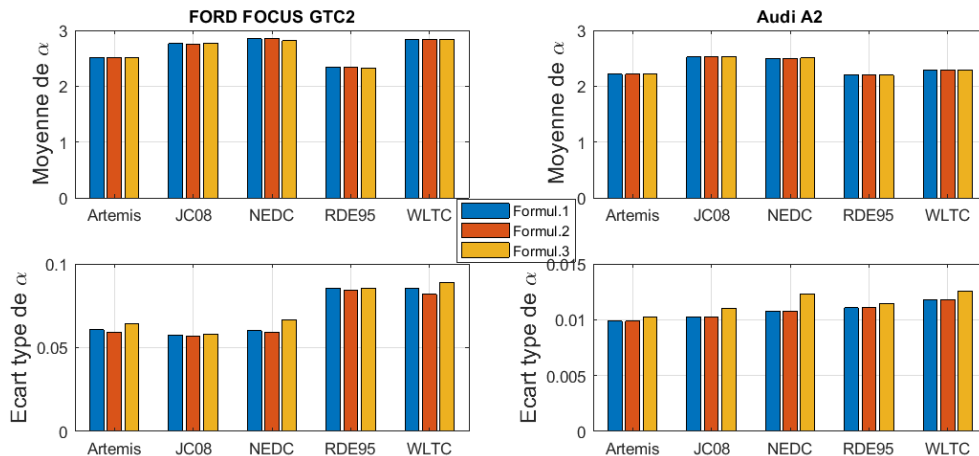


FIGURE 3.9 – Moyennes et écarts types du coefficient de pondération α pour les trois formulations du *PMP Energy Management*

Les trois formulations du PMP peuvent alors être considérées équivalentes, car les Hamiltoniens à minimiser en temps-réel sont équivalents à 1% près. Cette conclusion se matérialise par des trajectoires similaires de *SoC* avec les différentes formulations du PMP, comme le montre la Figure 3.10. Il est à noter que les trajectoires données par la DP ont aussi la même allure. Les trajectoires ne sont cependant pas confondues, comme dans les cas pour la Ford Focus WLTC ou JC08 Audi A2, où la différence de trajectoires est claire. Cette différence est due aux pics que l'on peut observer sur la Figure 3.8, qui sont dus aux pics de courant de la batterie. Au moment de ces pics, la différence entre les α de chacune des formulations se retrouve multipliée par 10. Cette différence change le minimum de l'Hamiltonien et donne différentes commandes pour les différentes formulations. Les pics de courant sont la conséquence de demandes de forts couples pendant des courtes durées, comme peuvent le faire des conducteurs "sportifs". Ce type de conduite ne favorise pas l'équivalence entre les trois formulations du *PMP Energy management*.

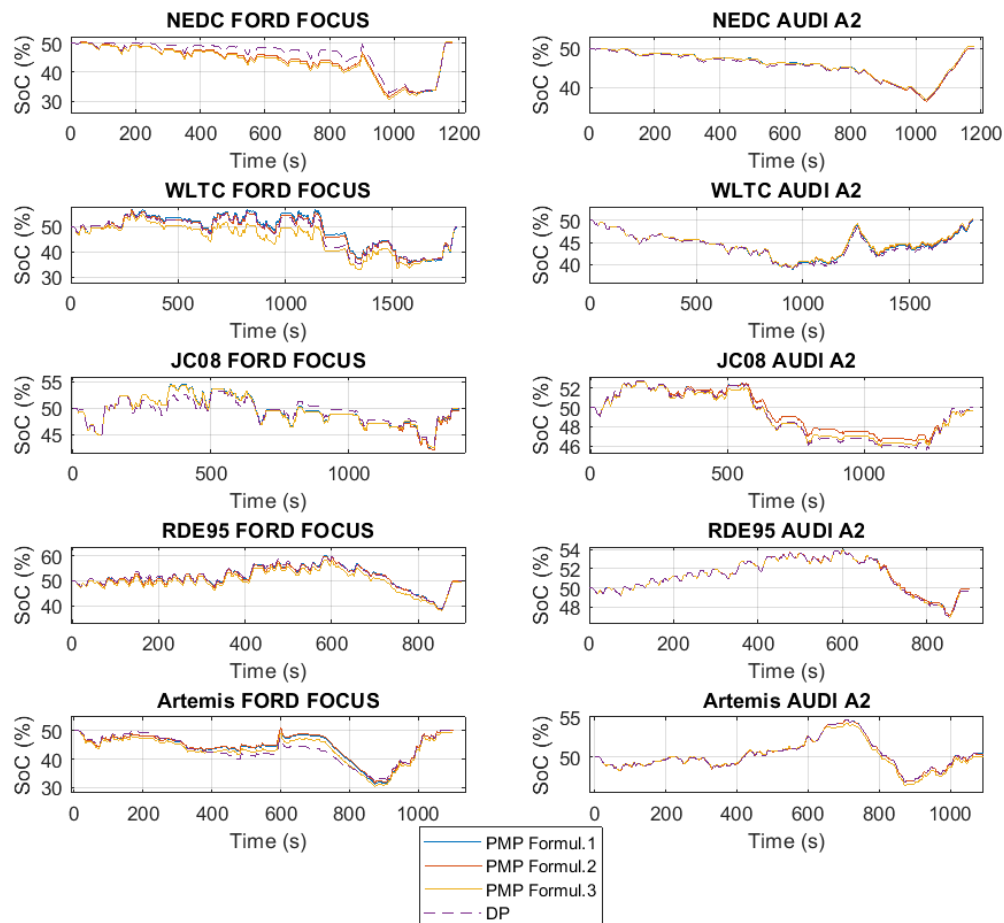


FIGURE 3.10 – Trajectoires de *SoC* sur les différents trajets simulés, avec PMP et DP

Le coefficient de pondération de l'Hamiltonien, qui est proportionnel à l'état adjoint, est ce qui donne plus ou moins de poids à l'énergie électrique dans l'optimisation. C'est ce qui

permet de garantir l'état de charge final souhaité. Pour le même état de charge visé, les résultats exposés montrent que les coefficients de pondération donnés par les trois formulations de la tension de la batterie dans le problème de contrôle optimal sont statistiquement équivalents. La Ford Focus, ayant une batterie à énergie inférieure, donne une plus grande différence entre les formulations sans que cela soit notable au niveau de la consommation de carburant. L'expression théorique de l'état adjoint (3.30) et (3.31) justifie la condition nécessaire à l'équivalence des trois formulations. Les pics de courant dus aux brusques et fortes demandes de couples nuisent également à l'équivalence des formulations de la tension de batterie. En pratique les constructeurs ne conçoivent pas une batterie pour un véhicule avec une énergie basse. Les pics de courant restent en général assez minoritaires sur un trajet. En conséquence, nous pouvons considérer que la formulation du problème avec une tension de batterie constante est équivalente aux formulations plus rigoureuses de la tension de la batterie qui permettent d'approcher l'optimum global donné par la DP.

3.3.1.3 Influence de l'Horizon de prédiction.

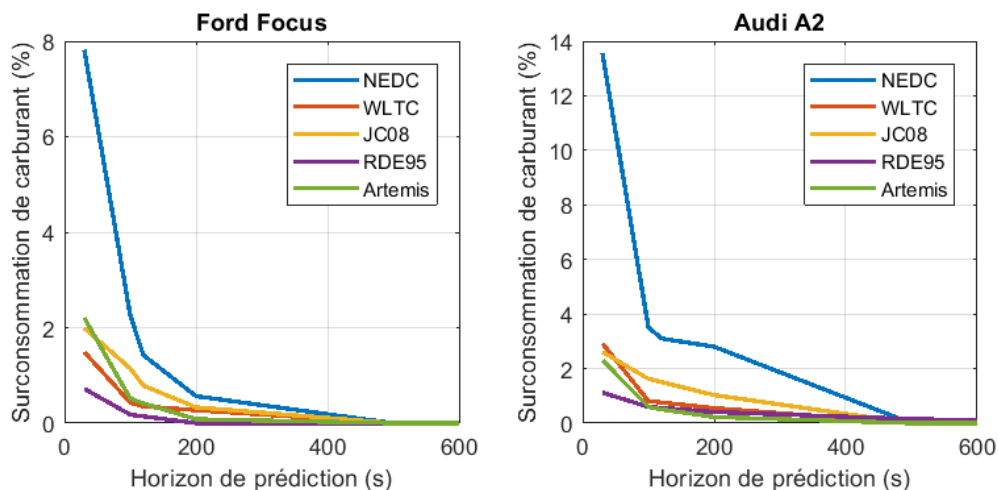


FIGURE 3.11 – Sur-consommation due à la diminution de l'horizon de prédiction

En faisant varier l'Horizon de prédiction (que nous noterons T) sur les différents trajets, avec les mêmes paramètres que ceux du Tableau 3.3, la solution optimale issue du PMP Energy management change. La Figure 3.12 montre l'évolution des trajectoires de SoC pour différentes valeurs d'horizon de prédiction. Avec la diminution de la taille de l'horizon de prédiction la trajectoire de SoC se rapproche de la valeur $SoC = SoC_f$. L'énergie électrique est alors de moins en moins utilisée pour ne pas s'éloigner de la consigne de SoC final. En conséquence, il y a plus de carburant qui est utilisé. Pour les valeurs d'horizon de prédiction assez petites ($T = T_f/100$ et $T = T_f/200$, T_f étant la longueur du trajet complet), il n'est plus possible d'anticiper la phase du freinage d'arrêt final, ce qui empêche la méthode de garantir l'état de charge désiré l'on se retrouve alors souvent en surcharge.

La Figure 3.11 montre les sur-consommations dues à la diminution de l'horizon de pré-

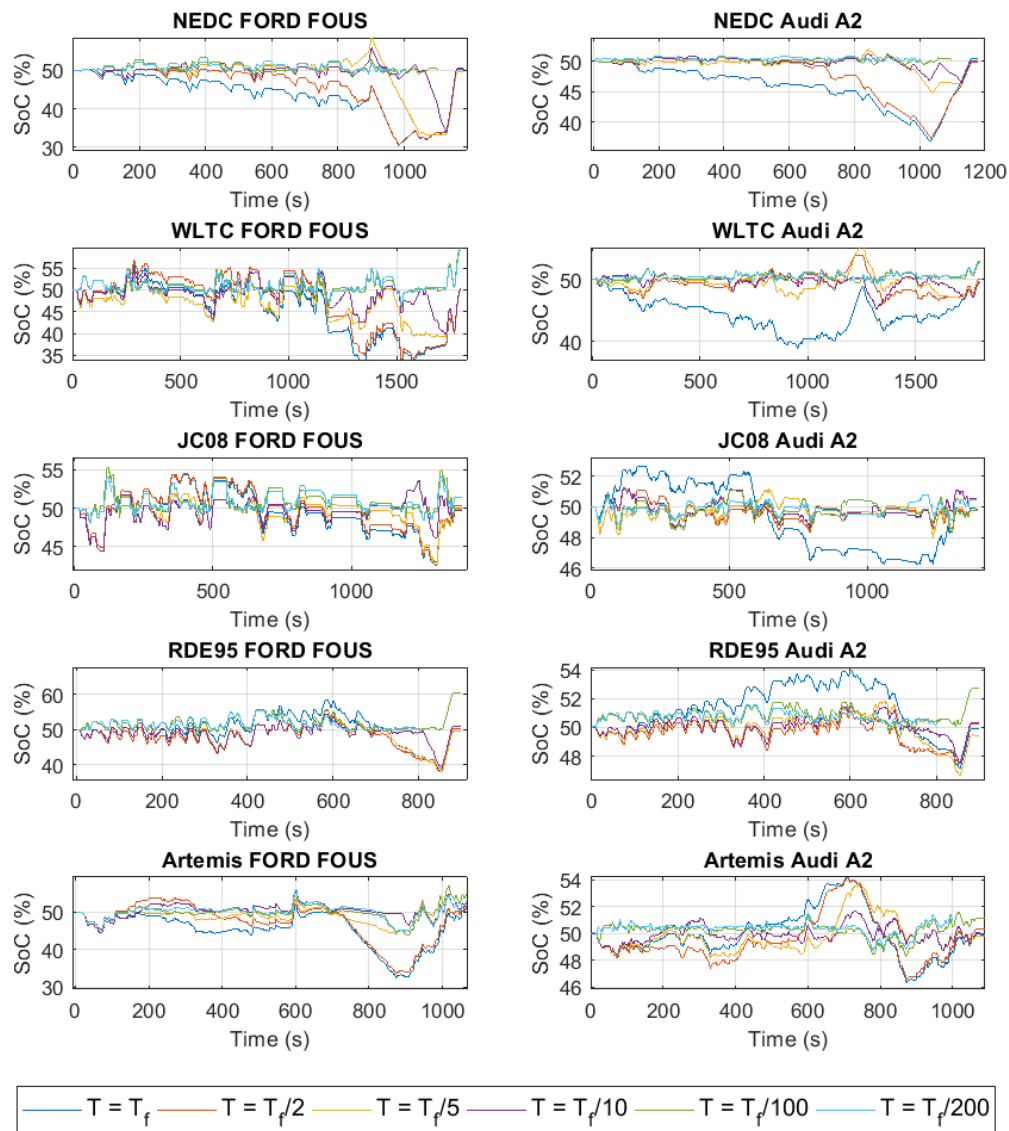


FIGURE 3.12 – Trajectoires de SoC avec différents durée de l’horizon de prédiction.

diction sur les différents trajets simulés. Ces résultats confirment les remarques faites sur les trajectoires de *SoC*. Plus l’horizon de prédiction diminue, plus de carburant est utilisé pour assurer une trajectoire de *SoC* proche de la valeur finale visée. D’autre part, un horizon de prédiction élevé peut mener vers une prédiction trop imprécise. La valeur d’horizon de prédiction à utiliser doit alors prendre en compte les incertitudes de la prédiction, ce qui sera discuté dans le chapitre 4.

3.3.2 Simulations de La Ford Focus GTC2 avec le modèle complet AMESim : Etude comparative avec la méthode CostBased.

Dans cette partie, la méthode PMP Energy management va être implémentée sur le modèle AMESim de la Ford Focus GTC2 48V fourni par Continental Automotive. Bien que les données utilisées dans le modèle d'optimisation soient issues de ce modèle AMESim, il ne décrit que les dynamiques nécessaires à l'*Energy management*. Par contre, le modèle AMESim décrit entièrement les dynamiques du véhicule, de la friction des roues aux pertes mécaniques des transmissions en passant par le circuit de refroidissement. C'est un des modèles de tests et de validations officiel de Continental.

Bien que cela ne soit pas une implémentation sur véhicule, cette simulation utilise la méthode *PMP Energy management* dans des conditions proches des conditions réelles. Le modèle du véhicule étant développé sous AMESim, la simulation va être une co-simulation entre AMESim et Simulink, le *PMP Energy Management* étant exécuté sous Simulink. Il communique avec le modèle véhicule AMESim à travers une interface en C comme illustré sur la Figure 3.13.

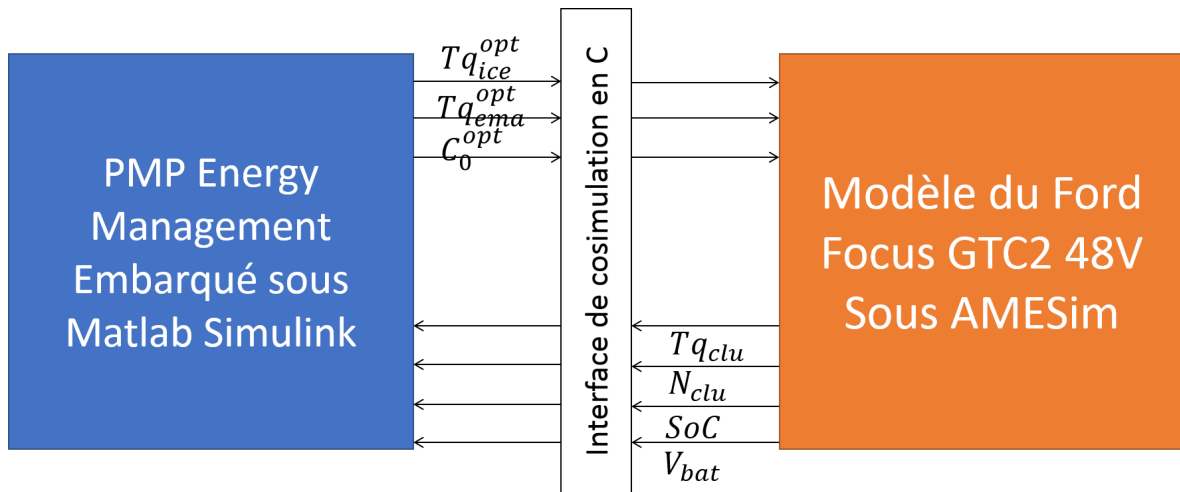


FIGURE 3.13 – Schéma de l'échange de données entre Matlab/Simulink et AMESim lors de la co-simulation du *PMP Energy Management* sur la Ford Focus GTC2 48V.

Deux trajets d'homologation CO_2 et deux trajets réels seront simulés (Annexe A) :

- Le cycle NEDC
- Le cycle WLTC
- Le cycle Falkenstein
- Le cycle RCC

Les paramètres du *PMP Energy management* lors de ces co-simulations sont identiques à ceux utilisés pour les simulations précédentes, à part le pas de calcul T_s :

TABLE 3.5 – Paramètres du *PMP Energy management* lors des co-simulations avec le modèle AMESim de la Ford Focus GTC2 48V

SoC_0	50%
SoC_f	50%
ϵ_{SoC}	0.5%
$[\alpha_{min}\alpha_{max}]_{init}$	[1, 4]
T_s	10ms
T (Horizon de prédiction)	Longueur du cycle étudié

3.3.2.1 Méthode CostBased :

Les résultats obtenus par la méthode du *PMP Energy management* sont comparés aux résultats de la méthode CostBased. Cette méthode a fait ses preuves en tant que meilleure méthode d'*Energy management* développée par Continental Automotive en terme de consommation de carburant et d'émission de CO_2 .

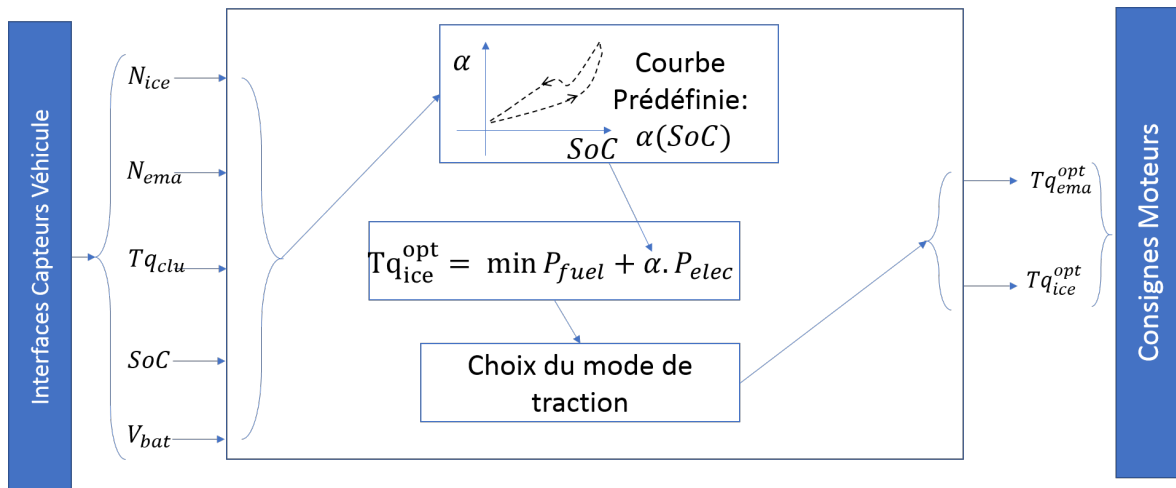


FIGURE 3.14 – Schéma résumant le principe de mise à jour du coefficient de pondération α dans la méthode CostBased.

La méthode CostBased s'inscrit dans la catégorie des méthodes temps-réel basées sur l'optimisation. Cette méthode est basée sur l'optimisation dans la mesure où elle obtient la répartition de couple en minimisant un critère pondéré :

$$P_{fuel} + \alpha \cdot P_{elec}$$

La différence par rapport à notre méthode basée sur le PMP réside dans le calcul du coefficient de cette pondération. La méthode CostBased se base sur des coûts optimaux pré-calculés sur chacun des points de fonctionnement (SoC, N, Tq). Le coût optimum correspond au meilleur rendement de conversion thermique vers électrique, et vice-versa. La cartographie de coûts pour chacun des points de fonctionnement définit alors une courbe $\alpha(SoC)$. La minimisation

du critère $P_{fuel} + \alpha(SoC).P_{elec}$ pour chacun des modes de tractions possibles donne alors la solution de répartition du couple. α n'est alors pas calculé en fonction d'un calcul de co-état, il est plutôt déduit à partir de règles appliquées sur les états instantanés du véhicule. Le *PMP Energy management* quant à lui utilise des informations futures pour calculer l'évolution de ce coefficient de pondération, de manière à trouver l'optimum sur la globalité du trajet. D'un autre côté, le CostBased s'affranchi de toute prédiction et adapte le coefficient de pondération à chaque pas de calcul, en fonction de règles pré-établies sur les états mesurés du véhicule. La comparaison de ces deux méthodes est alors une comparaison de l'approche prédictive qu'est le *PMP Energy management* et de l'approche adaptative matérialisée par le CostBased.

La méthode CostBased, par conception, n'a donc aucune garantie d'atteindre la valeur précise de l'état de charge final souhaitée. Bien que le PMP Energy management, grâce à l'algorithme de tirs indirect, est conçu pour atteindre cette valeur, les écarts qu'il y a entre le modèle de référence utilisé dans le contrôle optimal et le modèle AMESim simulé augmentent le risque de s'écarter de la valeur SoC_f souhaitée.

Les deux méthodes pouvant donner des états de charge finaux différents, la comparaison des consommations de carburant sera biaisée. La comparaison se portera alors sur les émissions de CO_2 équivalentes. Cette grandeur est obtenue en convertissant l'énergie électrique correspondante à l'erreur en SoC en son équivalent de carburant. Cette énergie est alors ajoutée à l'énergie du carburant consommé durant le trajet et la somme est convertie en grammes de CO_2 (Annexe C).

3.3.2.2 Résultats des co-simulations.

Les résultats des co-simulations, sur les 4 trajets et pour chacune des deux méthodes, sont résumés dans le tableau 3.6. Pour chacun des trajets sont calculés : la consommation de carburant, l'écart global en état de charge de la batterie $SoC_f - SoC_0$, et l'émission équivalente de CO_2 .

Le *PMP Energy management* donne pour chacun des cycles une meilleure consommation de carburant. Malgré le résultat négatif en terme d'écart en état de charge sur le trajet Falkenstein, l'équivalent CO_2 obtenu avec le *PMP Energy management* reste dans tous les cas meilleur que celui obtenu par le CostBased (tableau 3.6).

Il est à noter que le CostBased obtient toujours une valeur d'état de charge final plus proche de SoC_f que celle obtenue par le PMP Energy Management. Ceci est dû au caractère boucle ouverte de la solution issue du PMP, car la calibration de l'état adjoint dans le PMP est faite au départ du trajet et n'est pas mise à jour. Les différences que comporte le modèle utilisé dans le contrôle optimal par rapport au modèle simulé donnent une évolution des états du système différente de celle calculée par notre méthode indirecte de tirs. On se retrouve alors avec une initialisation du co-état qui ne correspond pas à l'état de charge final souhaité. La distance entre l'état de charge obtenu et l'état de charge souhaité reflète la précision du modèle d'optimisation : l'erreur sur état de charge diminue quand le modèle d'optimisation est plus précis. D'un autre côté, le CostBased en tant que méthode de catégorie "temps-réel basée

TABLE 3.6 – Résultats des co-simulations sur Ford Focus GTC2 48V avec PMP et CostBased.

PMP Energy Management (prédictif)			
	Consommation [g de fuel]	Variation globale de SoC [%]	Émissions équivalentes de CO_2 [g/km]
NEDC	327	+4	92.38
WLTC	869.32	+2.16	117.79
Falkenstein	2279.94	-0.4	123.17
RCC	584.19	+0.74	100.15
CostBased (adaptatif)			
	Consommation [g de fuel]	Variation globale de SoC [%]	Émission équivalente de CO_2 [g/km]
NEDC	332	+0.5	94.67
WLTC	872.17	+0.72	118.33
Falkenstein	2297.6	+0.85	123.97
RCC	591.3	-0.16	101.55

sur l'optimisation", scrute l'état du SoC et contrôle la valeur du coefficient de pondération en permanence afin de rester proche de la valeur finale de l'état de charge souhaitée.

TABLE 3.7 – Résultats des simulations sur cycle urbain du *PMP Energy Management* avec 4 initialisations différentes : émissions CO_2 équivalentes comparées au résultat Costbased.

	Variation globale de SoC [%]	Emissions de CO_2 équivalentes [g/km]
PMP avec α_0^1	-4.14	151.92
PMP avec α_0^2	-0.87	151.15
PMP avec α_0^3	+1.27	150.72
PMP avec α_0^4	+5.61	151.09
CostBased	-3.9	152.77

Malgré l'imprécision du modèle d'optimisation, provoquant une erreur sur l'état de charge final, le *PMP Energy management* donne dans tous les cas de plus faibles émissions de CO_2 équivalentes. Un cycle urbain de 5km fourni par Continental est simulé avec 4 différentes initialisations du co-état ($\alpha_0^1 < \alpha_0^2 < \alpha_0^3 < \alpha_0^4$) pour modéliser chacune une petite variation dans le modèle d'optimisation, menant à une petite variation dans l'initialisation de l'état adjoint. Les résultats de variation de SoC et d'émission de CO_2 équivalentes sont exposés dans le tableau 3.7. La monotonie de $f(\alpha_0)$ se confirme dans cette série de simulations et l'état de charge final augmente avec la valeur de α_0 . La différence en consommation de carburant induite par ces différentes valeurs de α_0 se traduisent en différentes valeurs d'émissions équivalentes de CO_2 . Toutes ses valeurs sont inférieures à celle obtenue par la méthode CostBased. La méthode *PMP Energy management* fait alors preuve de robustesse quant à l'imprécision de son modèle de référence. Il est à noter que ces imprécisions ont comme seul impact une valeur de α_0 qui mènera vers un SoC final différent de celui souhaité. Cet impact est identique à celui d'une imprécision de prédiction.

TABLE 3.8 – Résultats des co-simulations sur Ford Focus GTC2 48V avec PMP et CostBased : Utilisation de l'énergie électrique

	<i>PMP Energy Management</i> (prédictif)		
	Freinage régénératif [<i>Wh</i>]	Conduite électrique pure [<i>Wh</i>]	Conduite hybride [<i>Wh</i>]
NEDC	199	218	18
WLTC	455	306	199
Falkenstein	656	144	178
RCC	524	294	80
	CostBased (adaptatif)		
	Freinage régénératif [<i>Wh</i>]	Conduite électrique pure [<i>Wh</i>]	Conduite hybride [<i>Wh</i>]
NEDC	194	82	24
WLTC	424	155	137
Falkenstein	617	114	171
RCC	484	189	158

Le tableau 3.8 fait état de l'utilisation de l'énergie électrique dans chacun des modes de conduite impliquant l'EMA. Il s'avère que le *PMP Energy management* permet un flux d'énergie électrique plus important. Le freinage régénératif restitue plus d'énergie pour chacun des trajets simulés avec le PMP Energy management. En contrepartie, les énergies électriques mises en jeu dans les phases de traction sont plus importantes, que ce soit en phase de conduite hybride, ou surtout en phase de traction électrique pure. Notre méthode basée sur Le PMP permet alors d'échanger plus d'énergie électrique lors du trajet, en fournissant plus d'énergie pour la traction et en récupérant plus d'énergie lors des phases de freinage.




FIGURE 3.15 – Evolution de l'état de charge de la batterie sur le trajet Falkenstein avec les méthodes PMP et CostBased.

Comme le montre la Figure 3.15, qui illustre l'évolution du *SoC* sur le trajet Falkenstein avec les deux méthodes simulées, l'utilisation de l'énergie électrique par le PMP Energy management mène à l'utilisation de la batterie avec une plus grande amplitude de son état

de charge. Par contre, la méthode CostBased reste le plus proche possible du *SoC* cible. Cette tendance correspond à la nature prédictive/adaptative de chacune des méthodes. La méthode Costbased adapte en temps-réel son paramétrage afin de satisfaire la contrainte en *SoC* et garde donc l'état de charge de batterie proche de l'état de charge visé (charge sustaining implicite). En tant que méthode prédictive, le *PMP Energy management* peut utiliser les prédictions pour anticiper la disponibilité d'énergie électrique par freinage régénératif. La méthode génère une solution qui permet alors d'utiliser plus d'énergie électrique et donc moins de carburant, sachant qu'elle pourra récupérer assez d'énergie dans le futur pour retrouver l'état de charge visé. Notons que cette anticipation n'est pas visée directement par l'algorithme, mais elle correspond à la solution optimale du problème de l'*Energy management* par le Principe du Maximum de Pontryaguin.

La co-simulation du *PMP Energy management* et sa comparaison à la méthode Costbased permettent de constater la performance du PMP dans un contexte plus proche de la réalité. Malgré les biais du modèle d'optimisation utilisé par rapport au modèle du véhicule simulé, la méthode parvient à obtenir de meilleurs résultats que la méthode Costbased, en terme d'émission de CO_2 équivalent. Cette co-simulation permet aussi de déceler l'apport qualitatif du *PMP Energy management* par rapport à une méthode *temps-réel* comme le CostBased. Le caractère prédictif de notre méthode basée sur le PMP permet une meilleure utilisation de l'énergie électrique.

3.3.3 Conclusions

Les simulations réalisées montrent que le *PMP energy management* peut atteindre l'optimum global obtenu par la DP, ce qui correspond aux attentes théoriques concernant la théorie du contrôle optimal et le Principe du Maximum de Pontryaguin. Le théorème du PMP donne une condition nécessaire d'optimalité locale dans le cas général. En particulier, dans le cas d'un problème avec des fonctions critères convexes, la condition devient nécessaire et suffisante pour une optimalité globale. Ceci semble être le cas dans une grande partie des cartographies de puissance ICE utilisées, comme le montrent les Figures 2.10 et 2.15.

La formulation rigoureuse du problème avec l'expression complète de la tension batterie donne un état adjoint variable, avec une expression qui fait intervenir une exponentielle, une intégrale, en plus de la nécessité de connaître les valeurs de tension et de courant de la batterie. La solution donnée avec l'hypothèse d'une tension de batterie constante est cependant assez proche de la solution rigoureuse basée sur la formulation 1. Théoriquement, il y a une condition pour que la formulation 3 soit équivalente à la formulation 1 : il faut d'abord que la capacité énergétique de la batterie soit élevée. Nous avons ensuite remarqué que les pics de courant demandés peuvent aussi avoir une influence sur cette équivalence. Dans les cas simulés, les formulations sont équivalentes (à moins de 1% près), malgré la présence de quelques pics de courant sur des trajets comme le WLTC, et malgré le fait que la batterie de la Ford Focus soit une batterie 'moyenne' de 48V 10A.h.

La nature prédictive du *PMP Energy management* impose la relation qu'il y a entre la

durée de l'horizon de prédiction et la consommation de carburant. L'augmentation de l'horizon de prédiction réduit la consommation globale sur le trajet, car cela donne plus de capacité d'anticipation à la méthode d'optimisation. Pour augmenter l'efficacité de la méthode, il faut alors chercher à avoir le plus grand horizon de prédiction possible. Néanmoins, l'hypothèse de fiabilité complète des prédictions est fautive dans les conditions réelles, et il est impossible d'avoir des prédictions précises sur des dizaines de minutes.

Dans le chapitre suivant, les incertitudes des prédictions seront prises en compte. L'influence de ces incertitudes sur le notre modèle déterministe de contrôle optimal sera montrée. Les prédictions seront modélisées par des variables aléatoires, et la robustesse de l'horizon de prédiction par rapport au modèle probabiliste utilisé sera étudiée.

PMP Energy Management Probabiliste

Sommaire

4.1 Incertitude des prédictions et influence sur l'état de charge de la batterie	81
4.2 Modélisation probabiliste	83
4.2.1 Prédiction à distributions normales instantanées	88
4.2.2 Prédiction modélisée par des chaînes de Markov	98
4.3 Comparaison des méthodes : Déterministe versus Probabiliste	107
4.4 Conclusions	109

Dans le chapitre précédent nous avons pu analyser la performance du PMP Energy management sous l'hypothèse de trajets complètement connus à l'avance. Cette hypothèse ne correspond pas à la réalité du temps réel. La connectivité des véhicules peut offrir une estimation (ou prédiction) sur ce trajet futur. Dans ce chapitre, nous modélisons cette estimation par des variables aléatoires. Ces variables aléatoires seront alors introduites dans la méthode du *PMP Energy management*, d'abord théoriquement sans préciser une loi de probabilité des prédictions. Ensuite, deux lois probabilistes seront étudiées : la loi normale instantanée et une chaîne de Markov. Nous appellerons la méthode issue de cette modélisation : le PMP Energy management probabiliste.

4.1 Incertitude des prédictions et influence sur l'état de charge de la batterie

La méthode *PMP Energy management* a l'avantage de concentrer l'effet de l'incertitude de la prédiction sur l'état de charge final. En effet, si une prédiction imprécise est utilisée par l'algorithme de tirs, l'état de charge final obtenu ne sera pas égal à l'état de charge visé. Par contre, la trajectoire de *SoC* qui aura eu lieu, sera la trajectoire optimale si l'on avait visé le *SoC* final atteint. En d'autres termes, l'optimalité en terme de consommation de carburant n'est pas directement influencée par la prédiction. On peut avoir une surconsommation si l'on surcharge la batterie, mais cela reviendrait tout de même à obtenir la solution optimale si on

visait cette surcharge. Pour illustrer ces propos, quelques simulations ont été réalisées avec l'Audi A2 Hybrid.

Le trajet Horsch (Annexe A) de 100km, dans la banlieue de la ville de Dresde en Allemagne, a été effectué 14 fois avec l'Audi A2 Hybrid. Chaque fois à la même heure de la journée. Les demandes de couples et de vitesses sont enregistrées. La simulation suivante prend comme prédiction le premier enregistrement des demandes des couples et vitesses, et prend comme trajet réel le deuxième enregistrement (Figure 4.1).




FIGURE 4.1 – Demandes du conducteur VS Prédictions des demandes

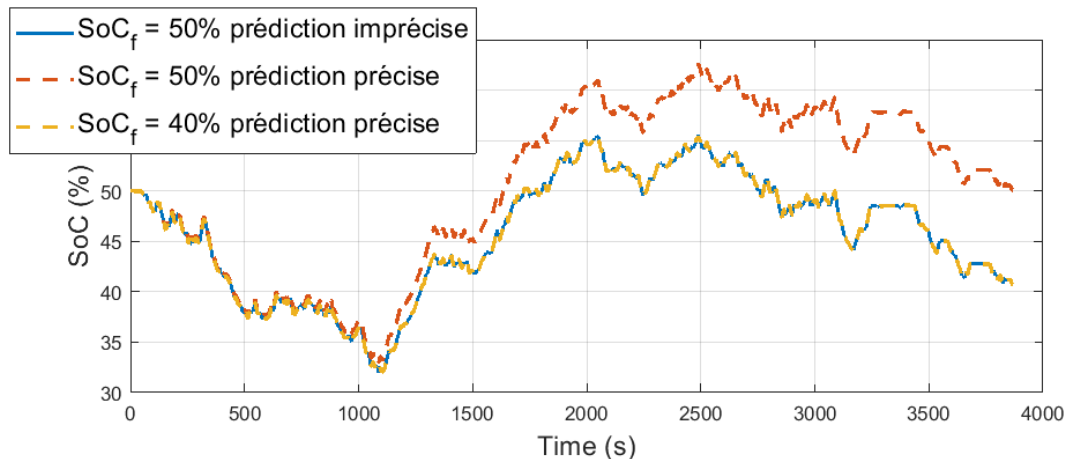


FIGURE 4.2 – Trajectoires de SoC avec prédictions précises/imprécises

La Figure 4.2 montre l'évolution de l'état de charge SoC obtenue avec cette prédiction, comparée au résultat dans le cas idéal d'une prédiction complètement fiable. Le SoC final

obtenu est éloigné de 10% de l'état de charge final visé $SoC_f = 50\%$, ce qui représente une décharge non désirée. Par contre, si le SoC visé est de $SoC_f = 40\%$, avec une prédiction complètement fiable, la trajectoire optimale correspond exactement à celle obtenue avec prédiction imprécise visant $SoC_f = 50\%$.

La prédiction imprécise se matérialise en un état de charge final différent de celui visé, mais cette solution correspond à la solution optimale au cas où le SoC visé est différent. En fait, même avec une initialisation du co-état aléatoire, si SoC_f est obtenu à partir d'un SoC_0 initial, cette solution serait la trajectoire optimale pour ramener l'état de charge de la batterie de SoC_0 à SoC_f . Pour cette raison, l'imprécision des prédictions pour le *PMP Energy management* n'influence pas directement la consommation de carburant, mais l'état de charge final de la batterie.

Ainsi le développement du *PMP Energy management probabiliste* a pour objectif de minimiser la déviation sur l'état de charge final. En modélisant les prédictions par des variables aléatoires, la distribution probabiliste de l'état de charge final sera calculée, puis la probabilité d'erreur sera minimisée.

4.2 Modélisation probabiliste

Le développement du *PMP Energy management probabiliste* se base sur la version déterministe. La solution optimale du problème sera nécessairement obtenue par la minimisation de l'Hamiltonien. La paramétrisation de ce dernier à travers l'initialisation du co-état est ce qui permet de garantir l'état de charge final souhaité. En prenant en entrée des prédictions complètement fiables, l'algorithme de tirs détermine le co-état initial parfait pour obtenir l'état de charge final souhaité. Dans le cas présent, les prédictions ne sont pas fiables, le PMP probabiliste consiste alors en une version probabiliste de l'algorithme de tirs, avec toujours une minimisation de l'Hamiltonien en temps-réel.

L'algorithme de tirs réitérera le calcul de la fonction f qui donne l'état de charge final en fonction de l'initialisation du co-état (3.2.1). La fonction f est une simulation de l'évolution de SoC en utilisant l'initialisation du co-état en entrée.

$$f(\lambda_0) = SoC(0) + \sum_{i=0}^n \frac{-1}{Q_{max}} \frac{P_{elec}(\frac{1}{\beta}(Tq_{clu}^i - C_0 \cdot Tq_{ice}^{opt}(\lambda_0)^i), \beta \cdot N_{clu}^i) + P_{aux}^i}{V_{bat}^i} \cdot dt \quad (4.1)$$

L'équation (4.1) représente la version discrétisée de l'équation (3.25), où $T = n \cdot dt$. Un instant t est alors égal à $i \cdot dt$, dt étant le pas d'intégration de l'équation.

Notons $(\hat{T}q_{clu}, \hat{N}_{clu})$ les variables aléatoires modélisant les demandes de couple et de vitesse du conducteur et $p_{Tq_{clu}, N_{clu}}$ la distribution de probabilité associée. L'espace des demandes

de couple et vitesse sera discrétisé, et nous allons utiliser l'espace à une dimension équivalent. Ceci nous permettra d'associer à chaque couple une distribution de probabilité. Ainsi à un instant $t = i.dt$, la prédiction est notée $(\hat{T}q_{clu}, \hat{N}_{clu})^i$ et sa distribution de probabilité est notée $p_{Tq_{clu}, N_{clu}}^i$. La fonction de tirs probabiliste est obtenue en insérant $(\hat{T}q_{clu}, \hat{N}_{clu})$ dans l'équation (4.1), ce qui donne :

$$\hat{f}(\lambda_0) = SoC(0) + \sum_{i=0}^n \frac{-1}{Q_{max}} \frac{P_{elec}(\frac{1}{\beta}(\hat{T}q_{clu}^i - C_0.Tq_{ice}^{opt}(\lambda_0)^i), \beta.\hat{N}_{clu}^i) + P_{aux}^i}{V_{bat}^i}.dt \quad (4.2)$$

La puissance électrique $P_{elec}^i = P_{elec}(\frac{1}{\beta}(\hat{T}q_{clu}^i - C_0.Tq_{ice}^{opt}(\lambda_0)^i), \beta.\hat{N}_{clu}^i)$ à l'instant t est donc une variable aléatoire dont la distribution de probabilité dépend de la distribution de probabilité de la prédiction $p_{Tq_{clu}, N_{clu}}^i$ et de λ_0 . Enfin, l'état de charge final donné par $\hat{f}(\lambda_0)$ est une variable aléatoire qui dépend des distributions de probabilités des prédictions sur tout le trajet et de λ_0 . Afin de calculer la distribution de probabilité de l'état de charge final $SoC(T) = \hat{f}(\lambda_0)$, il faut tout d'abord calculer la distribution de probabilités de Tq_{ice}^{opt} , ce qui permettra le calcul de la probabilité de P_{elec}^i puis de $\hat{f}(\lambda_0)$.

Les distributions de probabilités sont discrètes. A un instant $t = i.dt$, la prédiction de couple et de vitesse est dans l'intervalle $(Tq_{clu}, N_{clu})^i \in [Tq_{clu}^{min}, Tq_{clu}^{max}] \times [N_{clu}^{min}, N_{clu}^{max}]$, qui est un espace à 2-dimensions. Nous discrétisons cet espace et considérons son équivalent à une dimension. Notons, l'espace de prédiction discrétisé :

$$(\hat{T}q_{clu}, \hat{N}_{clu})^i \in \{(Tq_{clu}, N_{clu})_1, ((Tq_{clu}, N_{clu})_2, \dots, (Tq_{clu}, N_{clu})_{m_{Pred}})\} \quad (4.3)$$

Ainsi, à l'instant $t = i.dt$, pour chacune de ces prédictions $(\hat{T}q_{clu}, \hat{N}_{clu})^i = (Tq_{clu}, N_{clu})_k$ est associée une probabilité $p_{Tq_{clu}, N_{clu}}^i(k)$. La fonction $p_{Tq_{clu}, N_{clu}}^i$ donne alors la distribution de probabilités de la demande de couple et de vitesse à l'instant $t = i.dt$, $(\hat{T}q_{clu}, \hat{N}_{clu})^i$.

Dans ce qui suit, pour une grandeur X , la valeur de la variable à l'instant $t = i.dt$ sera notée X^i . La variable aléatoire associée à cette valeur sera notée \hat{X}^i . L'espace des valeurs de X est discrétisé :

$$X \in \{X_1, X_2, \dots, X_{m_X}\} \quad (4.4)$$

La $k^{\text{ème}}$ valeur possible sur l'espace discret des valeurs possibles sera notée X_k . La distribution de probabilité de \hat{X}^i est notée p_X^i , de façon à avoir $p_X^i(k) = P(\hat{X}^i = X_k)$.

Distribution de probabilités de $Tq_{ice}^{\hat{opt}}$

Soit un instant $t = i.dt$ et un $\alpha = \frac{-\lambda}{Q_{max}V_{bat}}$ (où λ et le co-état du problème de contrôle optimal (3.1.3) fixés . Le couple optimal à cet instant est le couple qui minimise l'Hamiltonien. L'Hamiltonien exprimé ci-après est cependant désormais une variable aléatoire puisque c'est la somme de deux variables aléatoires $\hat{P}_{fuel}^i = P_{fuel}(Tq_{ice}, \hat{N}_{clu}^i)$ et $\hat{P}_{elec}^i = P_{elec}(\frac{1}{\beta}(\hat{T}q_{clu}^i - C_0.Tq_{ice}), \beta.\hat{N}_{clu}^i)$.

$$\hat{H}^i(Tq_{ice}) = \hat{P}_{fuel}^i + \alpha.\hat{P}_{elec}^i \quad (4.5)$$

A la prédiction $(\hat{T}q_{clu}, \hat{N}_{clu})^i = (Tq_{clu}, N_{clu})_k$ correspond un Hamiltonien $\hat{H}^i = H_k(Tq_{ice})$.

$$H_k(Tq_{ice}) = P_{fuel}(Tq_{ice}, N_{cluk}) + \alpha.P_{elec}(\frac{1}{\beta}(Tq_{cluk} - C_0.Tq_{ice}), \beta.N_{cluk}) \quad (4.6)$$

La minimisation de l'Hamiltonien est faite sur l'intervalle $Tq_{ice} \in [Tq_{min}, Tq_{max}]$. La discrétisation de cet intervalle donne :

$$Tq_{ice} \in \{Tq_1, Tq_2, \dots, Tq_{m_{Tq}}\} \quad (4.7)$$

Pour déterminer la distribution de probabilités de $Tq_{ice}^{\hat{opt}}(i)$, il suffit de déterminer la probabilité de $Tq_{ice}^{opt}(i) = Tq_j$ pour tout $j \in \{1, 2, \dots, m_{Tq}\}$.

A chacune des prédictions possibles $(\hat{T}q_{clu}, \hat{N}_{clu})^i = (Tq_{clu}, N_{clu})_k$ correspond un couple optimal Tq_j qui minimise l'Hamiltonien \hat{H}_k^i .

$$\forall k \in \{1, 2, \dots, m_{Pred}\} \exists j \in \{1, 2, \dots, m_{Tq}\}, tq \quad Tq_j = \arg \min_{Tq_{ice}} (H_k(Tq_{ice})) \quad (4.8)$$

Pour $j \in \{1, 2, \dots, m_{Tq}\}$ la probabilité que $Tq_j = Tq_{ice}^{opt}(i)$ est la somme des probabilités des prédictions pour lesquelles Tq_j minimise l'Hamiltonien.

$$\forall j \in \{1, 2, \dots, m_{Tq}\} \quad P(Tq_j = Tq_{ice}^{opt}) = \sum_{k/Tq_j = \min(H_k)} p_{Tq_{clu}, N_{clu}}^i(k) \quad (4.9)$$

Ainsi, en ayant déterminé pour chacune des valeurs de couple moteur possibles sa probabilité d'être une solution optimale, la distribution de probabilités de $Tq_{ice}^{\hat{opt}}$ est complètement déterminée.

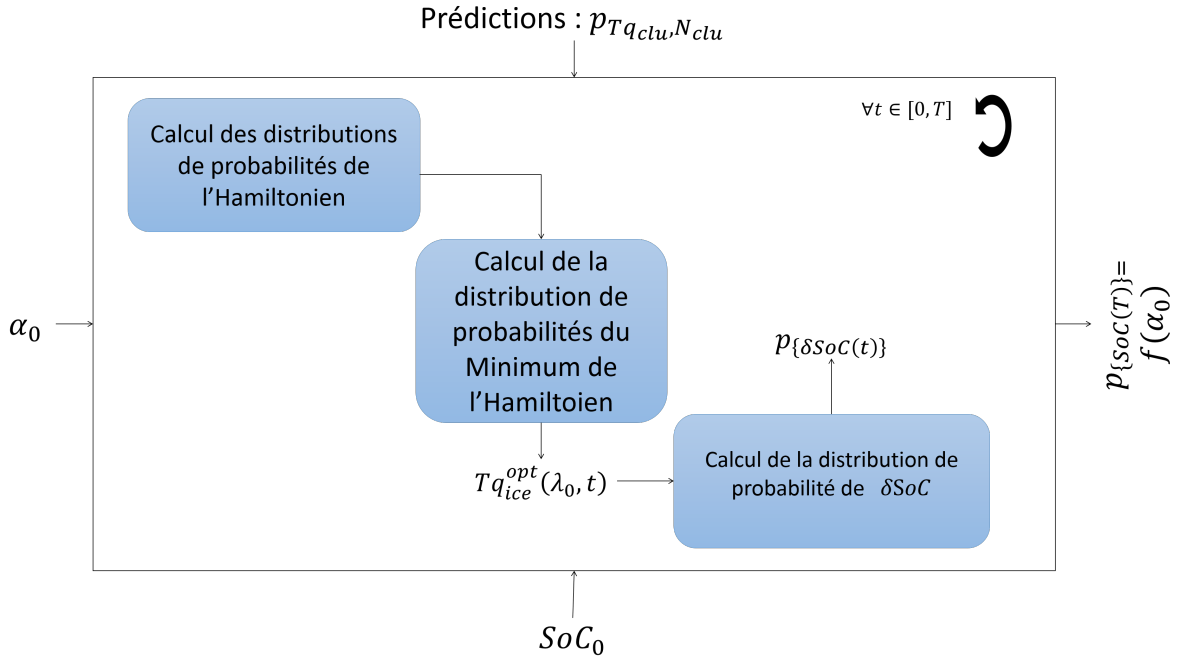


FIGURE 4.3 – Fonction de tirs probabiliste \hat{f} : Calcul de la distribution de probabilités de l'état de charge final en fonction de l'initialisation du co-état, et des distributions de probabilités des prédictions

Distribution de probabilités de \hat{P}_{elec}

Par le même procédé, la distribution de probabilités de \hat{P}_{elec} est obtenue. La puissance électrique varie sur l'intervalle discrétisé :

$$P_{elec}^i \in \{P_{elec1}, P_{elec2}, \dots, P_{elec m_P}\} \quad (4.10)$$

Pour déterminer la densité de probabilités de \hat{P}_{elec}^i , il suffit de déterminer la probabilité de $P_{elec}^i = P_{elec j}$ pour tout $j \in \{1, 2, \dots, m_P\}$.

L'expression de \hat{P}_{elec} est :

$$\hat{P}_{elec}^i = P_{elec} \left(\frac{1}{\beta} (\hat{T}q_{clu} - C_0 \cdot Tq_{ice}^{opt}(i)), \beta \cdot \hat{N}_{clu} \right) \quad (4.11)$$

Pour tout $j \in \{1, 2, \dots, m_P\}$, la probabilité pour que $P_{elec}^i = P_{elec j}$ est égale à la somme des probabilités des différentes prédictions possibles pour lesquelles le couple optimal consomme la puissance électrique $P_{elec j}$.

$$\forall j \in \{1, 2, \dots, m_P\} \quad P(P_{elec}^i = P_{elec_j}) = \sum_{k/P_{elec_j}=P_{elec}} \frac{1}{\beta} p_{Tq_{clu}, N_{clu}}^i(k) \quad (4.12)$$

Ainsi en ayant déterminé les probabilités de chacune des valeurs possibles de la puissance électrique, la distribution de probabilités de \hat{P}_{elec} est complètement déterminée. La distribution de probabilités de la variation $\delta \hat{SoC}$ de SoC due à \hat{P}_{elec} peut alors être déduite sachant que :

$$\delta SoC = -\frac{P_{elec}}{Q_{max} V_{bat} \cdot dt} \quad (4.13)$$

Notons $p_{\delta SoC}$ la densité de probabilité de δSoC . Puisque :

$$SoC(T) - SoC(0) = \sum_{i=1}^N \delta SoC^i$$

la variation globale de SoC sur tout le trajet a pour densité de probabilités :

$$p_{SoC(T)-SoC(0)} = p_{\delta SoC}^1 * p_{\delta SoC}^2 * \dots * p_{\delta SoC}^N \quad (4.14)$$

où * est le produit de Cauchy (ou produit de convolution en continu).

Pour un α fixé, les procédés ci-dessus permettent de calculer la distribution de probabilité de la variation globale de SoC .

Ainsi, notre algorithme de tirs probabiliste fait varier le α jusqu'à trouver une distribution de probabilité de $SoC(T) - SoC_0$ qui minimise le risque d'erreur (d'écart) sur l'état de charge final visé SoC_f . Cet algorithme de tirs probabiliste utilise aussi une dichotomie (Figure 4.4 et Figure 4.3).

Les développements théoriques présentés dans cette partie se basent sur une définition générale et abstraite de la distribution de probabilités pour modéliser les prédictions de vitesses et de couples $p_{(Tq_{clu}, N_{clu})}$. Selon la distribution probabiliste utilisé, la prédiction peut être plus ou moins représentative de la demande réelle. Les deux parties suivantes appliquent la méthode proposée sur deux modèles probabilistes particuliers. La validité de chacun de ces modèles sera discutée en fonction de la durée de l'horizon de prédiction.

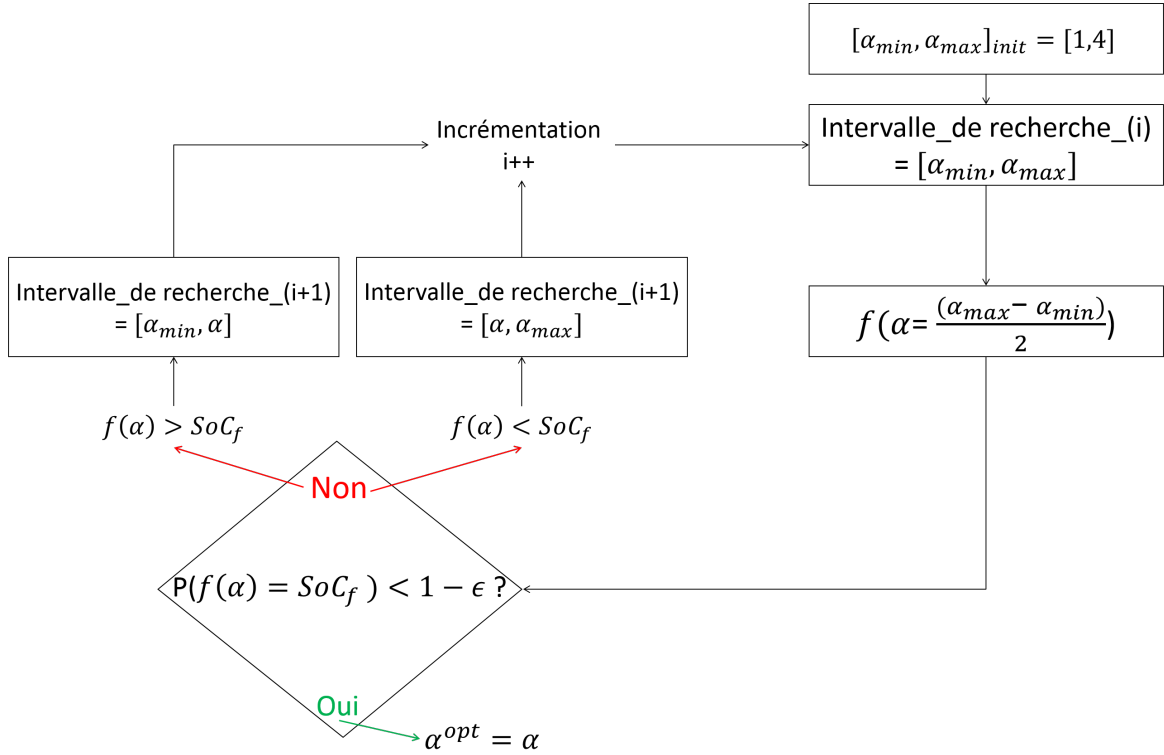


FIGURE 4.4 – Schéma de l’algorithme de tirs probabiliste avec dichotomie

4.2.1 Prédications à distributions normales instantanées

Le premier modèle probabiliste consiste en une distribution normale modélisant Tq_{clu}^i et N_{clu}^i à chaque instant $t = i.dt$. Cette distribution a l’avantage d’être caractérisée par deux scalaires : la moyenne et l’écart type. A un instant $t = i.dt$, la demande de couple et de vitesse est caractérisée par $(M_{Tq}^i, \sigma_{Tq}^i, M_N^i, \sigma_N^i)$, où M représente la moyenne et σ représente l’écart type.

Le produit de Cauchy nécessaire (équation (4.14)) dans une formulation générale pour calculer la distribution de probabilités de la variation globale d’état de charge à partir des distributions de probabilités de variation instantanée δSoC , n’est pas nécessaire avec une modélisation probabiliste normale. En effet, en notant $M_{\delta SoC}^i, \sigma_{\delta SoC}^i$ la moyenne et l’écart type de $\delta \hat{SoC}$, la densité de probabilités de variation globale peut se calculer plus simplement :

$$M_{SoC(T)-SoC_0} = \sum_{i=1}^n M_{\delta SoC}^i \quad (4.15)$$

$$\sigma_{SoC(T)-SoC_0} = \sqrt{\sum_{i=1}^n \sigma_{\delta SoC}^i{}^2} \quad (4.16)$$

Néanmoins, il n’est pas évident d’affirmer que δSoC^i a une densité de probabilités norma-




FIGURE 4.5 – Distribution de probabilités de la puissance électrique pour des entrées normalement distribuées

lement distribuée. La puissance électrique P_{elec} est une fonction non-linéaire, et ne conserve pas forcément la distribution normale. Même si en son entrée les variables $\hat{T}q_{clu}$ et \hat{N}_{clu} sont normalement distribuées, \hat{P}_{elec} n'est pas forcément normalement distribuée.

Dans le cas du véhicule étudié et de la cartographie de puissance électrique associée, des simulations statistiques sont effectuées pour analyser la distribution de probabilités de $P_{elec}(Tq, N)$ en supposant une distribution normale pour Tq et N . Pour chacun des cas illustrés, 1000 instances de distributions normales de Tq et N sont générées et la puissance électrique correspondante est calculée. Les 1000 instances de $P_{elec}(\hat{T}q, \hat{N})$ sont utilisées pour calculer les distributions de probabilités dont quelques exemples sont illustrés dans la Figure 4.5.

Pour les différents cas, la distribution de probabilités peut être approchée par une distribution normale. Bien que l'on ne montrera pas rigoureusement que \hat{P}_{elec} conserve la distribution normale, l'hypothèse que $P_{elec}(\hat{T}q, \hat{N})$ est normalement distribuée sera adoptée. Pour pouvoir calculer la distribution de probabilités dans l'algorithme de tirs, on construit, hors-ligne,

une cartographie donnant la moyenne et l'écart type de \hat{P}_{elec} en fonction de la moyenne et l'écart type de ses entrées Tq et N . Cette cartographie pourra être utilisée en temps-réel pour approcher la distribution de probabilités de \hat{P}_{elec} .

Génération des moyennes et des écarts types instantanés

A partir de différents enregistrements d'un même trajet, les prédictions instantanées normalement distribuées peuvent être générées. Soit Z le nombre d'enregistrements $(Tq_{clu}, N_{clu})(z)$, $z \in \{1, 2, \dots, Z\}$. A l'instant $t = i.dt$, la moyenne et l'écart type de (Tq_{clu}^i, N_{clu}^i) sont donnés par :

$$M_{Tq_{clu}}^i = \frac{1}{Z} \sum_{z=1}^Z Tq_{clu}^i(z) \quad (4.17)$$

$$M_{N_{clu}}^i = \frac{1}{Z} \sum_{z=1}^Z N_{clu}^i(z) \quad (4.18)$$

$$\sigma_{Tq_{clu}}^i = \sqrt{\frac{1}{Z} \sum_{z=1}^Z (M_{Tq_{clu}}^i - Tq_{clu}^i(z))^2} \quad (4.19)$$

$$\sigma_{N_{clu}}^i = \sqrt{\frac{1}{Z} \sum_{z=1}^Z (M_{N_{clu}}^i - N_{clu}^i(z))^2} \quad (4.20)$$

Les prédictions sont alors entièrement définies à chaque instant. Ces équations sont appliquées sur les enregistrements du trajet Horscha. La Figure 4.6 représente les moyennes et les écarts types calculés.

Dans ce qui suit, deux premières simulations vont permettre de valider théoriquement l'algorithme de tirs probabiliste avec un horizon de prédiction maximal. Une troisième simulation appliquera cet algorithme aux enregistrements réels, avec le même horizon de prédiction. Puis, la durée l'horizon de prédiction variera afin d'étudier son influence sur la consommation et la précision sur l'état de charge final.

Horizon de prédiction maximal

Les simulations sont effectuées avec les paramètres du tableau 4.1 :

En prenant l'horizon de prédiction égal à la durée totale du trajet, le PMP Energy management probabiliste avec prédictions normalement distribuées est validé sur l'Audi A2. La validation se fera on vérifiant statistiquement (Test numérique 2) la distribution de probabilité que prédit l'algorithme de tirs probabiliste (Test numérique 1). Le Test numérique 3 testera le α^{opt} obtenu par l'algorithme de tirs probabiliste sur les 14 enregistrements réels.




FIGURE 4.6 – Moyennes et écarts types des demandes de vitesses et couples générés à partir des enregistrements Horscha

TABLE 4.1 – Paramètres du PMP Energy management probabiliste lors des simulations de validation des distributions normalement distribuées

SoC_0	50%
SoC_f	50%
ϵ	0.2
$[\alpha_{min}\alpha_{max}]_{init}$	[1, 4]
T_s	100ms
T (Horizon de prédiction)	Longueur du cycle étudié

Test numérique 1 L'algorithme de tirs probabiliste, à partir des distributions normales calculées de $T_{q_{clu}}$ et N_{clu} , donne une initialisation de l'état adjoint $\alpha_0 = 2.547$. L'algorithme prévoit un état de charge final \hat{SoC} normalement distribué de moyenne 49.9% et d'écart type 6.09%, comme le montre la Figure 4.7.

Notons que l'écart type de \hat{SoC} augmente avec le temps. Plus le temps est court, moins il y a de chance de s'écarter de la valeur cible de SoC .

Test numérique 2 Une série de simulations du trajet Horscha applique l'initialisation du co-état calculée par l'algorithme de tirs lors du Test numérique 1, sur 100 trajets générés




FIGURE 4.7 – Évolution de la moyenne et de l'écart type de l'état de charge \hat{SoC} prédits par l'algorithme de tirs probabiliste sur le trajet Horscha avec des distributions normalement distribuées

aléatoirement à partir de la prédiction normalement distribuée.

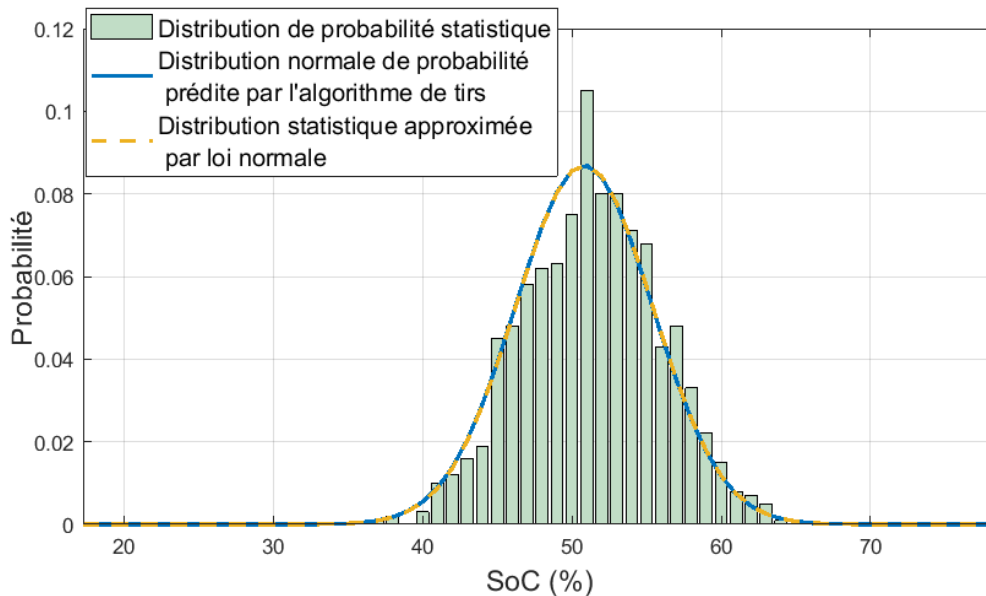


FIGURE 4.8 – Distribution de probabilités statistique à partir des 100 simulations comparée à la distribution de probabilités prédite par l'algorithme de probabilité.

Sur la Figure 4.8, la probabilité, calculée statistiquement à partir des 100 simulations, est comparée à la distribution de probabilités prédite par l'algorithme de tirs. La valeur moyenne des 100 $SoC(T)$ obtenus est de 49.7% et l'écart type est de 5.9%. L'algorithme de tirs avait prédit une moyenne de 49.9% et une écart type de 6.08%. Statistiquement les résultats correspondent alors aux prédictions de l'algorithme de tirs à moins de 1% près. Ce résultat permet de valider l'efficacité l'algorithme de tirs sur des trajets dont les prédictions

peuvent être modélisées par une forme de distribution normale. La correspondance entre les résultats de l'algorithme de tirs et de la statistique faite par le Test numérique 2 permet également de conclure que l'hypothèse adoptée sur \hat{P}_{elec} est valide.

Les trajets réels ne sont cependant pas rigoureusement modélisables par des distributions normales instantanées. Il reste alors à utiliser le résultat de l'algorithme de tirs probabiliste sur les trajets Horscha réels.

Test numérique 3 : Les 14 enregistrements du trajet Horscha sont simulés avec l'initialisation α_0 calculée par le Test numérique 1. Les résultats sont illustrés sur la Figure 4.9.




FIGURE 4.9 – États de charges finaux issus de la simulation des 14 trajets Horscha avec l'initialisation du co-état du Test numérique 1 (Distributions normales)

La moyenne et l'écart type ne correspondent pas aux prédictions de l'algorithme de tirs probabiliste. La distribution normale instantanée ne garantit pas une robustesse par rapport aux incertitudes avec l'horizon de prédiction utilisé.

La Figure 4.7 qui illustre la distribution de probabilités prédite par l'algorithme de tirs, montre que l'écart type augmente avec la durée de la prédiction. Le PMP Energy probabiliste est testé dans la partie suivante avec des horizons de prédictions plus petits.

Horizon de prédiction variable

Dans les trois simulations précédentes l'horizon de prédiction correspond à la totalité du trajet. Le α calculé par l'algorithme de tirs probabiliste a été utilisé sur 100 trajets différents. Les résultats de $SoC(T)$ ont alors été statistiquement similaires à la prédiction de l'algorithme de tirs. Néanmoins, sur les trajets réels qui servent à construire ces distributions et avec

l'horizon de prédiction maximal, le α calculé par l'algorithme de tris probabiliste ne permet pas de retrouver un état de charge final proche de l'état de charge final souhaité.




FIGURE 4.10 – Comparaison de la distribution de probabilités prédite par l'algorithme de tirs et la distribution donnée par les simulations sur les trajets réel en fonction de l'Horizon de prédiction

Les simulations 1 et 3 sont reproduites cette fois avec des horizons de prédiction plus petits. La Figure 4.10 montre la différence des distributions de probabilités entre la prédiction de l'algorithme de tirs probabiliste et les résultats sur les 14 enregistrements.

Pour les horizons de prédiction inférieurs à 200s la valeur moyenne des $SoC(T)$ des trajets réels correspond à 1% près à la prédiction de l'algorithme de tirs, et pour les horizons de prédictions inférieurs à 100s les écarts types se confondent à 1% près. Notons que l'erreur en écart type augmente avec l'accroissement de l'horizon de prédiction, jusqu'à ce que la valeur moyenne devienne proche de 100% de l'état de charge, ce qui mène vers une diminution de l'écart type. En effet, avec la prédiction imprécise due à l'horizon de prédiction trop grand, l'état de charge obtenu lors des trajets réels surcharge la batterie jusqu'à saturation. Et puisqu'il est impossible d'obtenir des valeurs de SoC supérieures à 100%, les valeurs de $SoC(T)$ sont limitées par cette saturation, ce qui empêche leur dispersion.

Le premier enregistrement Horschha est simulé avec le PMP Energy management probabiliste avec loi normale, avec différents horizons de prédiction. Les différentes trajectoires de SoC sont illustrées sur la Figure 4.11.

Les trajectoires présentent des oscillations pendant la partie extra-urbaines du trajet (entre 1000s et 3000s). La fréquence des oscillations augmente avec un horizon de prédiction plus petit. Par contre, l'amplitude des oscillations est plus élevée pour les horizons de prédiction plus grands. Lors des phases extra-urbaines, les demandes de puissances sont élevées. L'imprécision

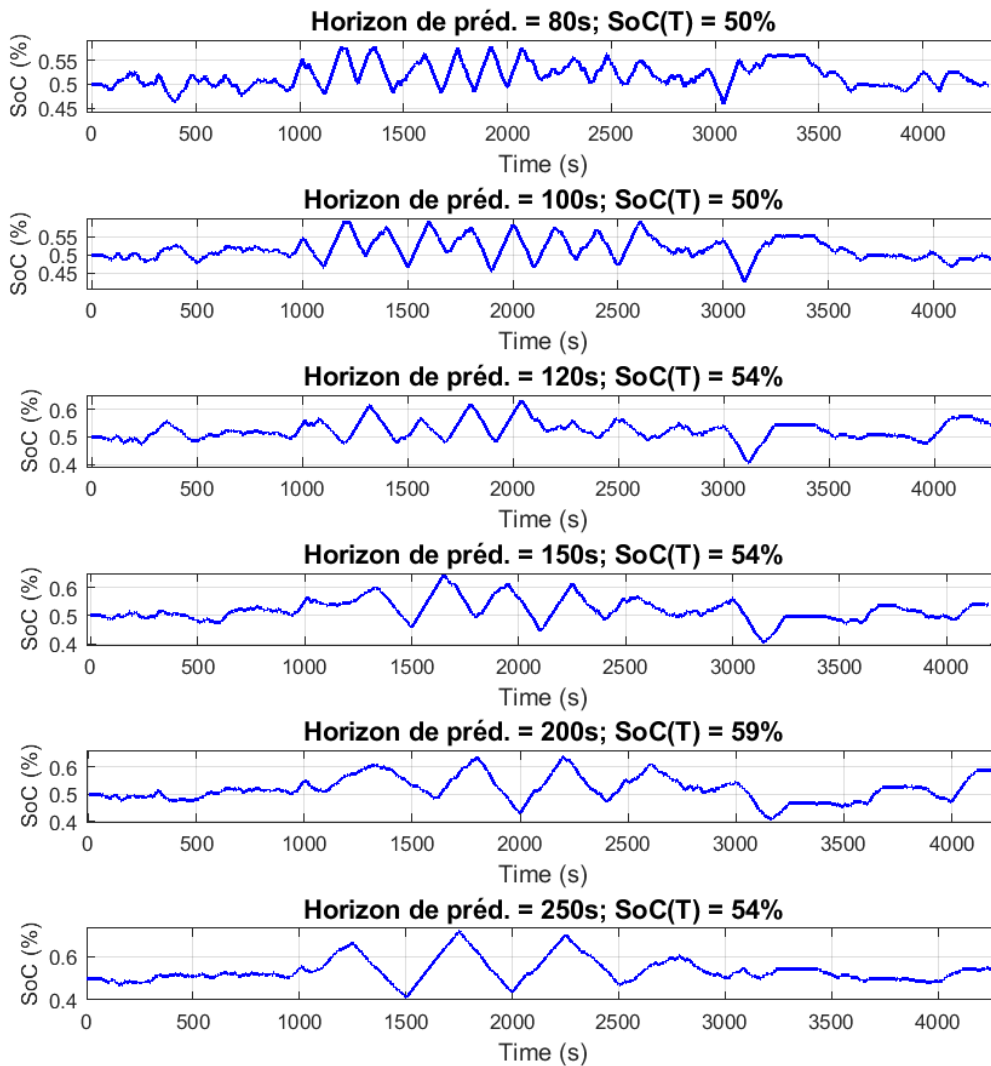


FIGURE 4.11 – Trajectoires de SoC issues du PMP probabiliste appliqué sur le premier enregistrement Horscha avec différents horizons de prédictions

de la prédiction mène alors vers une plus grande erreur en terme de SoC . L'algorithme de tirs probabiliste ré-initialise l'état adjoint à chaque nouvel horizon de prédiction, ce qui explique la relation entre la fréquence et l'amplitude des oscillations, et l'horizon de prédiction.

Pour étudier l'influence de l'horizon de prédiction sur la consommation de carburant et émission de CO_2 , les 14 trajets Horscha sont simulés avec le PMP Energy management probabiliste avec des prédictions normalement distribuées et avec différents horizons de prédiction. Les parties urbaines et extra-urbaines sont simulées séparément.

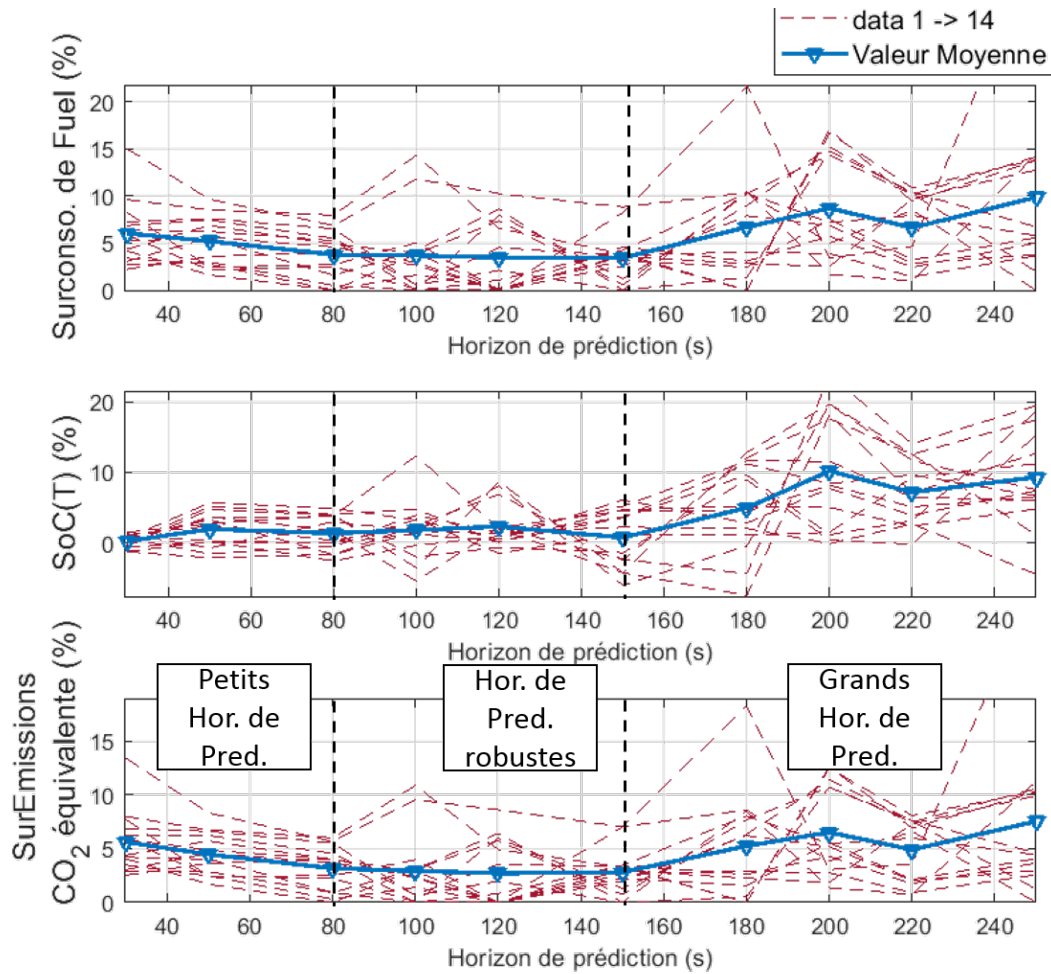


FIGURE 4.12 – Partie urbaine du trajet Horschha : Sur-consommation de carburant, erreurs en état de charge final, et sur-émissions de CO_2 équivalent, en fonction de l’horizon de prédiction.

Sur la Figure 4.12 sont illustrées, la surconsommation (par rapport à la meilleure consommation) de carburant, l’erreur en état de charge final $SoC(T) - SoC_f$ et les sur-émissions équivalentes de CO_2 (par rapport à la meilleure émission), sur la partie urbaine du trajet. Les horizons de prédiction inférieurs à 80s permettent de garantir l’obtention de la valeur visée de $SoC(T)$. Les horizons de prédiction longs de 80s et 150s donnent une erreur de 1.5% en moyenne sur l’état de charge final, mais garantissent une meilleure consommation de carburant et de plus faibles émissions de CO_2 . Les horizons de prédiction supérieurs à 150s peuvent dans certains cas donner une meilleure consommation, mais une erreur moyenne sur l’état de charge finale de 8%. Les petits horizons de prédiction ré-initialisent la valeur de α_0 de manière plus fréquente, et assurent donc de rester proche de la valeur cible de SoC . Néanmoins, cet aspect ne permet pas à la méthode d’anticiper plus loin dans le temps, ce qui aurait permis d’obtenir une meilleure consommation globale. Les grands horizons de prédiction permettent cette anticipation, mais à partir d’un certain seuil, le modèle probabiliste utilisé perd de la

précision, et l'erreur sur le *SoC* final devient trop élevée. L'intervalle des horizons de prédiction permettant une anticipation sur le futur tout en gardant de la précision sur l'état de charge final est entre 80s et 150s. Cette intervalle permet les meilleures consommations de carburant et les plus faibles émissions de CO_2 . Cela permet d'anticiper les valeurs futures des demandes de puissances du conducteur tout en restant robuste par rapport à l'état de charge final visé. La Figure 4.13 montre les trajectoires de *SoC* avec un petit horizon de prédiction, un horizon de prédiction robuste, et un grand horizon de prédiction.




FIGURE 4.13 – Trajectoires de *SoC* sur un trajet Horscha en utilisant différents horizons de prédiction

Pour la partie extra-Urbaine, l'influence de l'horizon de prédiction est moins importante que dans la partie urbaine. Si dans la partie urbaine un choix judicieux d'horizon de prédiction peut économiser jusqu'à 8% sur les émissions de CO_2 , dans la partie extra-urbaine les économies d'émission de CO_2 sont entre 2% et 3%. Il est possible de définir un intervalle d'horizon de prédiction robuste entre 60s et 100s où les gains en consommation et émission sont légèrement meilleurs que dans la zone des petits horizons de prédiction. La présence des oscillations de trajectoire *SoC*, dues aux grandes puissances utilisées dans la partie extra-urbaine, diminue l'efficacité de la méthode par rapport à la partie urbaine.

Les émissions de CO_2 en moyenne sur les 14 enregistrements du trajet Horscha sont comparées sur la Figure 4.15. Le PMP Energy management probabiliste à prédictions normalement distribuées émet $9g/km$ de CO_2 de plus sur la partie extra-urbaine par rapport à la partie urbaine. Les prédictions normalement distribuées peuvent permettre un horizon de prédiction robuste jusqu'à 150s sur les parties urbaines. Sur les parties extra-urbaines, l'imprécision du modèle probabiliste utilisé mène à une plus grande erreur en *SOC* à cause des grandes puissances mises en jeu.

Le modèle probabiliste a une influence sur la précision en *SoC*, et donc aussi sur la consommation de carburant et sur les émissions de CO_2 . Dans la prochaine partie, un deuxième modèle probabiliste des prédictions sera étudié.

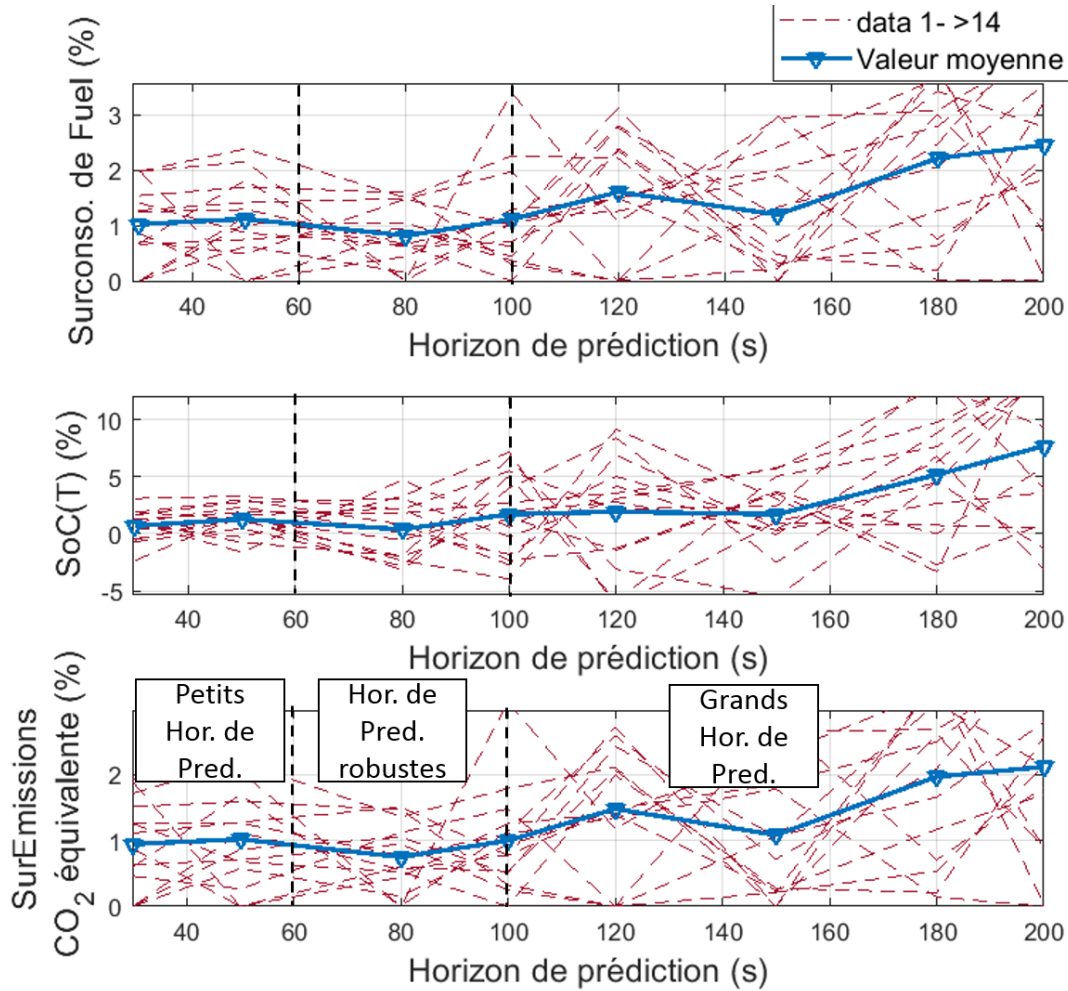


FIGURE 4.14 – Partie extra-urbaine du trajet Horschla avec prédictions normalement distribuées : Sur-consommation de carburant, erreurs en état de charge final, et sur-émissions de CO_2 équivalent, en fonction de l’horizon de prédiction.

4.2.2 Prédictions modélisées par des chaînes de Markov

Le deuxième modèle probabiliste des prédictions de couples et vitesses est une chaîne de Markov. Une chaîne de Markov est une séquence de variables aléatoires X_i . Pour un k donné, la distribution de probabilités de la variable X_{k+1} dépend entièrement de la valeur prise par X_k . La chaîne de Markov est alors déterminée par la distribution de prédiction de X_0 , et par les distributions de prédiction de passage d’un état à l’autre pour chaque indice k . Ce qui constitue la matrice de transition de passage ([93]).

Dans notre cas, la séquence de variables aléatoires modélise les prédictions $(\hat{T}_{q_{clu}}, \hat{N}_{clu})$. L’axe de prédiction étant discrétisé selon l’équation (4.3), à un instant $t = i.dt$ la probabilité de $(\hat{T}_{q_{clu}}, \hat{N}_{clu})^i = (T_{q_{clu}}, N_{clu})_k$ dépend de la valeur de $(\hat{T}_{q_{clu}}, \hat{N}_{clu})^{i-1}$. Notons $P_{j,k}$ la

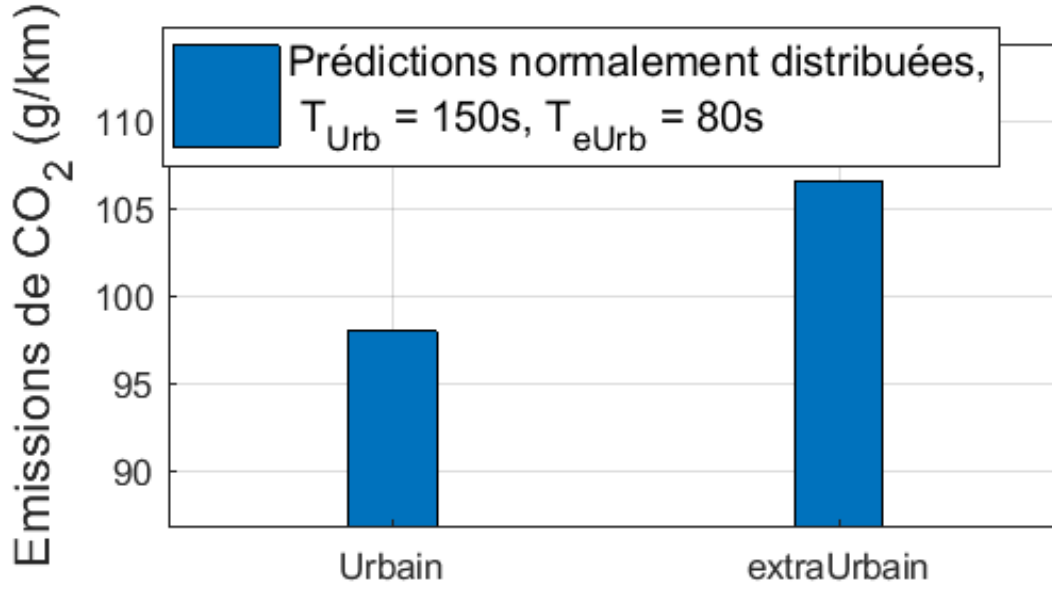


FIGURE 4.15 – Comparaison des émissions de CO_2 avec PMP probabiliste et prédictions normalement distribuées : Parties urbaines vs Partie extra-urbaine.

probabilité de passer de $(T_{qclu}, N_{clu})^j$ à $(T_{qclu}, N_{clu})^k$:

$$P_{j,k} = P[(\hat{T}_{qclu}, \hat{N}_{clu})^i = (T_{qclu}, N_{clu})_j \text{ et } (\hat{T}_{qclu}, \hat{N}_{clu})^{i+1} = (T_{qclu}, N_{clu})_k] \quad (4.21)$$

La chaîne de Markov modélisant les prédictions est alors caractérisée par sa matrice de transition τ :

$$\tau = (P_{j,k})_{1 < k < m, 1 < j < m} \quad (4.22)$$

A partir d'une distribution de probabilités $p_{(T_{qclu}, N_{clu})}^1$ de la prédiction à l'instant initial, il est possible de calculer la probabilité de chacune des prédictions possibles. A un instant $t = i.dt$:

$$\forall k \in \{2, 3, \dots, m\} \quad p_{(T_{qclu}, N_{clu})}^i(k) = \sum_{j=1}^m \tau_{k,j}^{i-1} \cdot p_{(T_{qclu}, N_{clu})}^1(j) \quad (4.23)$$

où τ^i représente la matrice τ élevée à la puissance i .

Ainsi la distribution de probabilités des prédictions est complètement définie et le calcul de la distribution de probabilités de $SoC(T)$ peut être effectué.

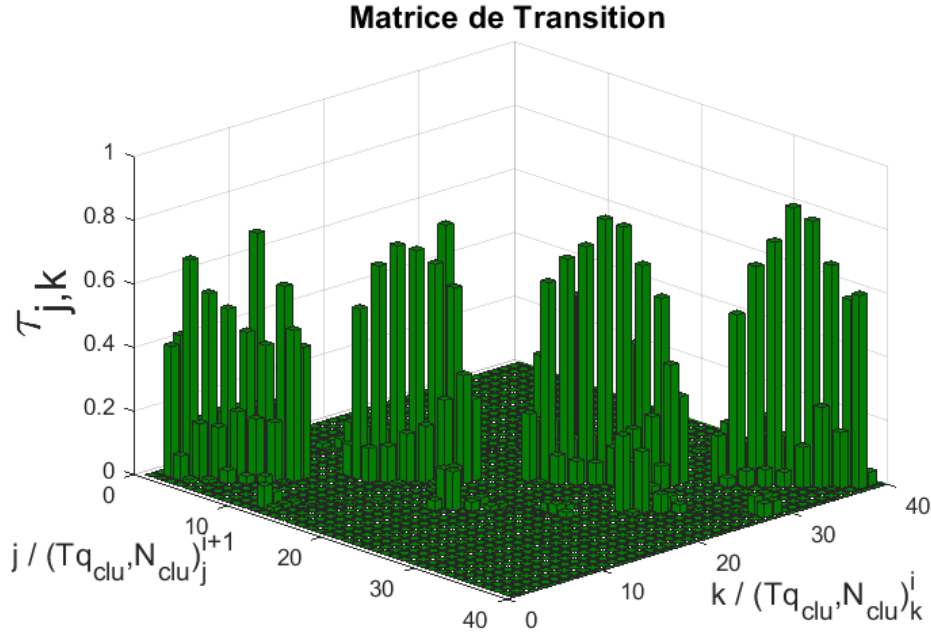


FIGURE 4.16 – Illustration d’une partie de la matrice de transition des prédictions des demandes de couples et vitesses sur le trajet Horscha.

Génération des matrices de transition et des probabilités de distributions

La matrice de transition d’une chaîne de Markov est générée à partir de différents enregistrements de (Tq_{clu}, N_{clu}) sur un trajet.

Soit Z le nombre d’enregistrements $(Tq_{clu}, N_{clu})(i)$, $i \in \{1, 2, \dots, Z\}$. La probabilité de passer de $(Tq_{clu}, N_{clu})_k$ à $(Tq_{clu}, N_{clu})_j$ est construite par :

$$\tau_{k,j} = \frac{1}{(n-1)Z} \sum_{z=1}^Z \text{Card} \left\{ i / (Tq_{clu}, N_{clu})(z)^i = (Tq_{clu}, N_{clu})_k \text{ et } (Tq_{clu}, N_{clu})(z)^{i+1} = (Tq_{clu}, N_{clu})_j \right\} \quad (4.24)$$

L’enregistrement z du trajet est parcouru, et le nombre de fois pour lesquelles la prédiction passe de $(Tq_{clu}, N_{clu})_k$ à $(Tq_{clu}, N_{clu})_j$ est comptabilisée. Ce calcul est effectué pour tous les enregistrements et les résultats sont sommés et divisés par le nombre total de points $(n-1)Z$. La matrice de transition est ainsi obtenue.

La matrice de transition obtenue à partir des enregistrements du trajet Horscha (Figure 4.16) permet de générer les distributions de probabilités instantanées, qui permettent de générer des cycles aléatoires correspondants aux modèles de la chaîne de Markov utilisée. La figure 4.17 montre un exemple de trajet généré à partir de la matrice de transition Horscha.

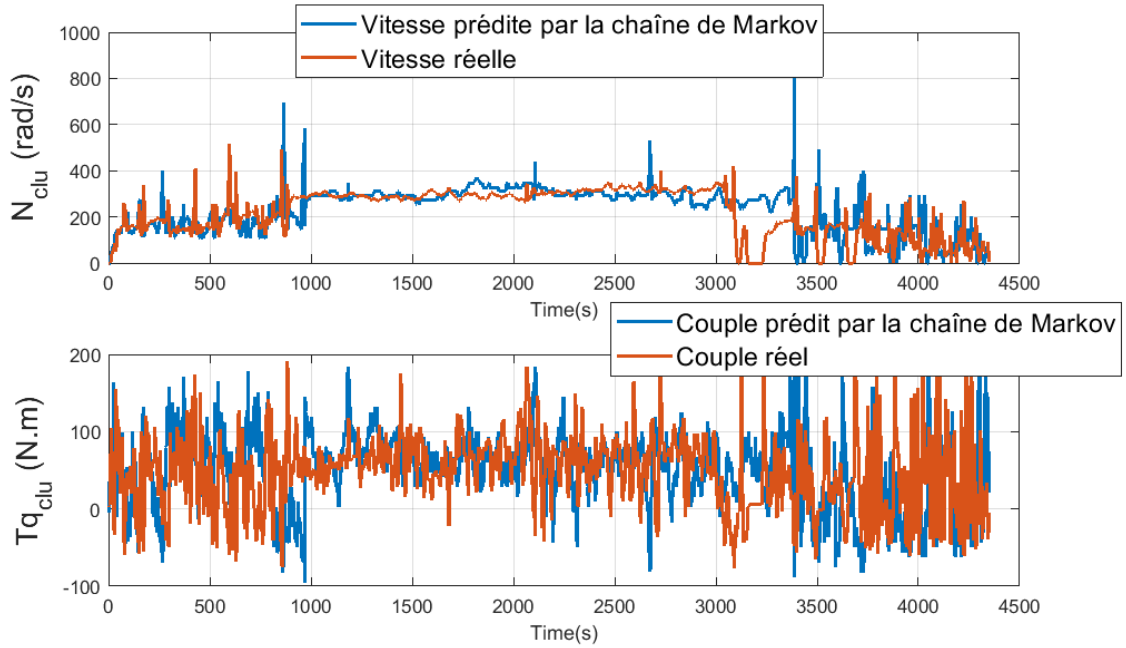


FIGURE 4.17 – Trajet générée à partir du modèle de Markov obtenu à partir des enregistrements Horscha.

Dans ce qui suit, la même série de simulations que pour les distributions normales vont être exposées. D’abord des simulations pour valider théoriquement l’algorithme de tirs probabiliste, avec horizon de prédiction maximal, en comparant sa prédiction au résultat statistique. Ensuite, l’application sur les enregistrements réels. Et enfin des simulations avec des horizons de prédiction permettant la robustesse de la solution.

4.2.2.1 Horizon de prédiction maximal

Les paramètres des simulations suivantes sont dans le tableau 4.2. Il est à noter que les valeurs minimales et maximales des intervalles de Tq_{ice} et de P_{elec} sont égales aux valeurs minimales et maximales instantanées imposées par la physique du système. Le nombre des points sur l’intervalle (m_P et m_{Tq}) discrétisé est par contre fixé.

Test numérique 1 : En utilisant un horizon de prédiction correspondant au trajet Horscha complet, l’algorithme de tirs probabiliste utilise la matrice de transition construite à partir des enregistrements. Il retourne alors la distribution de probabilités de l’état de charge final $SoC(T)$, ainsi que l’initialisation de l’état adjoint optimale α_0 .

L’état de charge final $S\hat{o}C(T)$ est normalement distribué. La moyenne est de 50% et l’écart type de 2.4%. Notons que le $\alpha_0 = 2.26$ trouvé ne correspond pas à la valeur trouvée par l’algorithme de tirs à distributions normales instantanées $\alpha_0 = 2.54$. On peut alors d’ores

TABLE 4.2 – Paramètres du PMP probabiliste lors des simulations de validation des distributions en chaînes de Markov.

SoC_0	50%
SoC_f	50%
ϵ	0.2
$[\alpha_{min}\alpha_{max}]_{init}$	[1, 4]
$(T_{clu}, N_{clu})_1$	$(-100N.m, 0)$
$(T_{clu}, N_{clu})_{m_{Pred}}$	$(216N.m, 892rad/s)$
m_{Pred}	50×50
m_{Tq}	100
m_P	100
T_s	100ms
T (Horizon de prédiction)	Longueur du cycle étudié

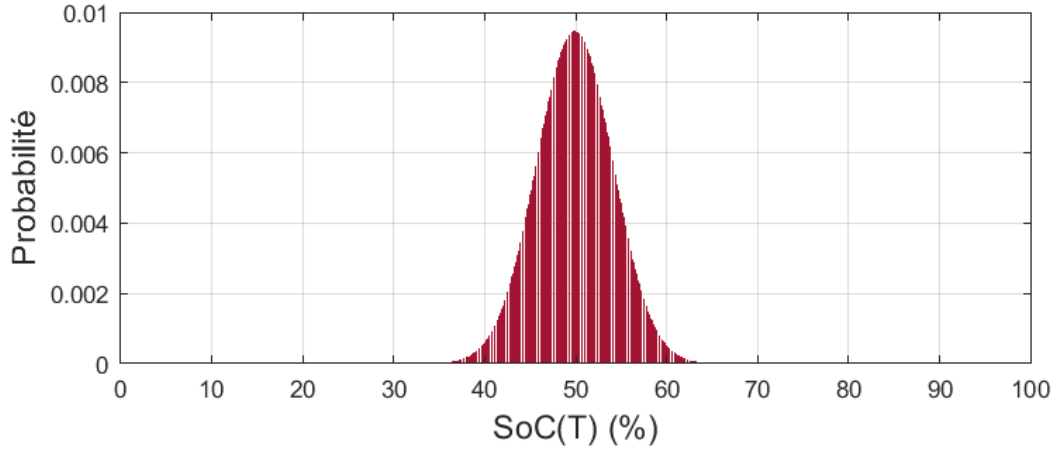


FIGURE 4.18 – Distribution de probabilités prédite par l’algorithme de tirs probabiliste avec distribution modélisée par chaîne de Markov.

et déjà s’attendre à un résultat différent lors de l’application sur les trajets réels.

Test numérique 2 : A partir de la matrice de transition de Markov, 100 trajets sont aléatoirement générés. Ils sont alors simulés, la minimisation de l’Hamiltonien s’effectuant avec le α_0 trouvé par l’algorithme de tirs dans la simulation précédente. (Figure 4.19)

La distribution statistique correspond quasiment à la distribution prédite par l’algorithme de tirs. La moyenne obtenue est de 49.74% et l’écart type 5.47%. La simulation montre l’efficacité de l’algorithme de tirs avec chaîne de Markov.

Test numérique 3 : Le α_0 trouvé dans le Test numérique 1 est utilisé sur les enregistrements Horscha.

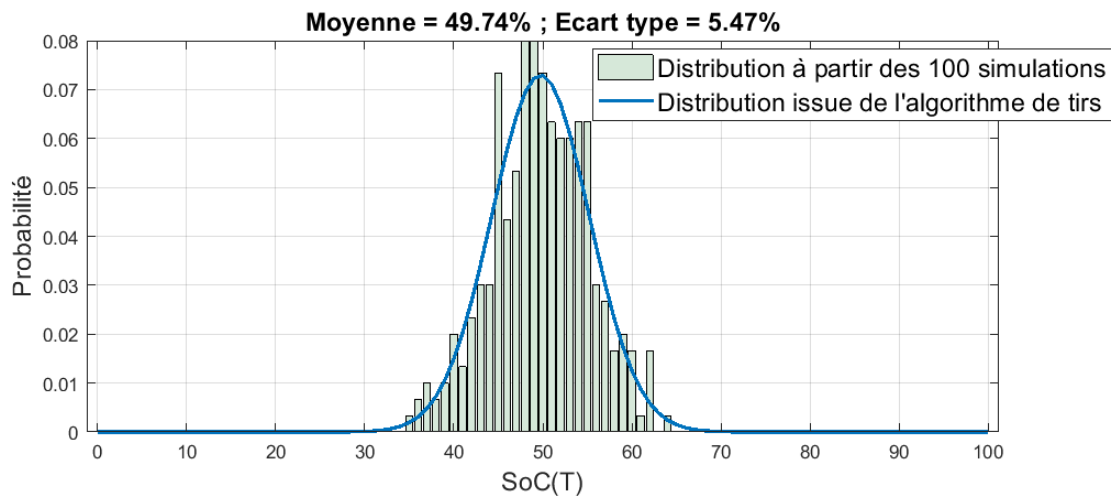


FIGURE 4.19 – Distribution de probabilités statistique comparée à la distribution de probabilités prédite par l'algorithme de tirs.




FIGURE 4.20 – Etats de charge finaux issus de la simulation des 14 trajets Horsch avec l'initialisation du co-état du Test numérique 1 (chaînes de Markov).

En moyenne sur les 14 trajets, l'état de charge final est de 41.57%, avec un écart type de 22.64%. Comparée aux prédictions normalement distribuées, la modélisation en chaîne de Markov permet de s'approcher en valeur moyenne de la valeur de la prédiction de l'algorithme de tirs. Par contre, l'écart type est élevé. Les chaînes de Markov ne permettent pas de fournir une modélisation robuste des prédictions avec un horizon de prédiction correspondant à la totalité du trajet.

Horizon de prédiction variable

De la même manière que pour les prédictions normalement distribuées, les Simulations suivantes visent à étudier l'influence de l'horizon de prédiction sur la consommation de carburant, l'état de charge final et les émissions équivalent CO_2 . Les parties urbaines et extra-urbaines sont également simulées séparément. Les Figures 4.21 et 4.22 illustrent les surconsommations de carburant (par rapport à la plus petite consommation), l'état de charge final et les sur-émissions de CO_2 équivalent (par rapport à la plus petite valeur d'émission).

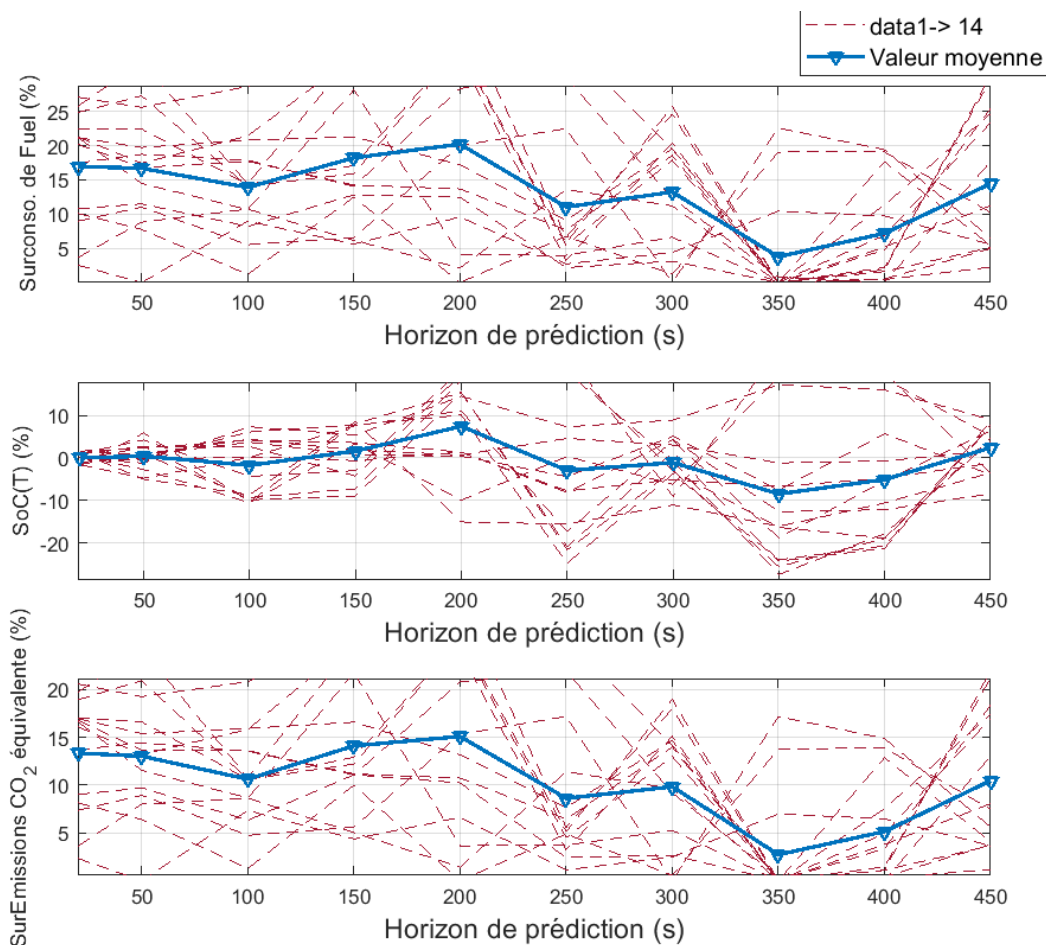


FIGURE 4.21 – Partie urbaine du trajet Horschka avec prédiction en chaînes de Markov : Sur-consommations de carburant, erreurs en état de charge final et sur-émissions de CO_2 équivalent, en fonction de l'horizon de prédiction.

Sur la partie urbaine, la meilleure performance en terme d'émission de CO_2 est obtenue en utilisant un horizon de prédiction de $T = 350s$. En moyenne, avec cet horizon de prédiction, la surconsommation est de 4%, et la sur-émission de CO_2 de 3%, tandis que l'état de charge final est de 41%. L'imprécision sur l'état de charge est importante, les valeurs trouvées sur les 14 trajets peuvent aller de -25% à $+15\%$. Pour un horizon de prédiction de 300s, la

sur-consommation moyenne de carburant est de 14% et la sur-émission de CO_2 de 10%. Par contre cet horizon de prédiction permet plus de robustesse par rapport à l'état de charge final avec un état de charge final moyen de 49%. L'analyse faite pour les résultats des prédictions normalement distribuées se confirme pour les prédictions sous forme de chaîne de Markov. Les petits horizons de prédiction permettent la précision en état de charge final, mais avec une consommation élevée par rapport aux horizons de prédiction plus grands. Les horizons de prédiction plus grands que 300s donnent une moindre consommation, mais sont imprécis quant à l'état de charge final qui sera atteint.

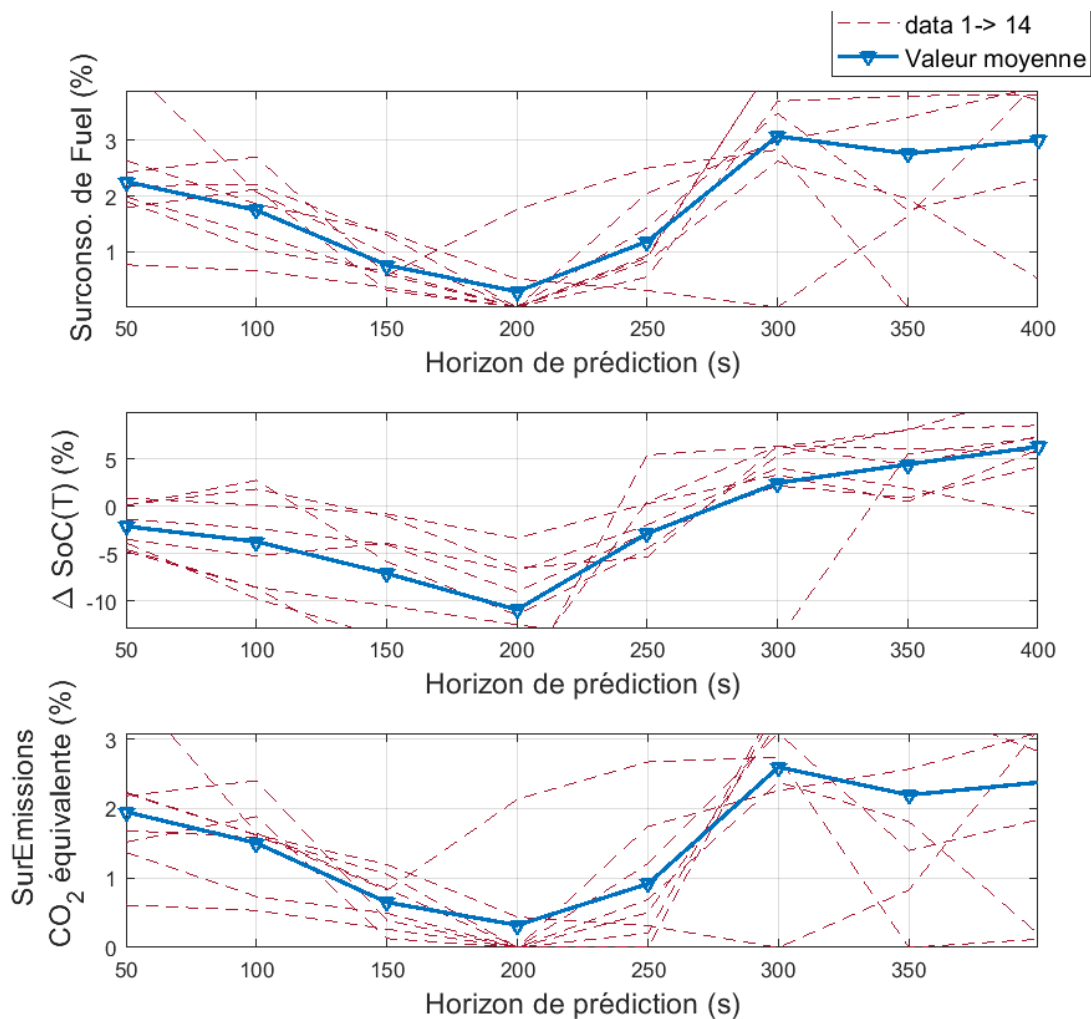


FIGURE 4.22 – Partie extra-urbaine du trajet Horscha avec prédictions en chaîne de Markov : Sur-consommations de carburant, erreurs en état de charge final, et sur-émissions de CO_2 équivalent, en fonction de l'horizon de prédiction.

Sur la partie extra-urbaine, encore une fois, l'horizon de prédiction ne permet pas d'économiser le même pourcentage de carburant et de CO_2 que sur la partie urbaine. Sur la partie extra-urbaine, il est possible d'économiser 2% de CO_2 et 3% de carburant, par rapport aux

12% d'émissions de CO_2 et de 15% de consommation de carburant. La meilleure performance est obtenue avec un horizon de prédiction de 200s, avec 0.4% de sur-émission de CO_2 et 0.3% de surconsommation de carburant, mais au prix d'un risque élevé de décharge de la batterie, avec en moyenne un état de charge final de 40%. Pour un horizon de prédiction de 100s, l'état de charge final est en moyenne de 46%, ce qui peut être plus acceptable, les sur-consommations de carburant et sur-émissions de CO_2 sont alors respectivement de 2% et 1.6%. L'utilisation de prédictions en chaîne de Markov ne permet pas de définir des valeurs d'horizon de prédiction robuste sur la partie extra-urbaine du trajet.




FIGURE 4.23 – Comparaison des émissions de CO_2 entre des prédictions en chaînes de Markov et des prédictions normalement distribuées.

Sur la Figure 4.23 sont illustrées les émissions moyennes de CO_2 sur le trajet Horscha en utilisant les horizons de prédiction robustes, 300s pour la partie urbaine et 100s pour la partie extra-urbaine. En comparaison avec les résultats obtenus avec les prédictions normalement distribuées, les chaînes de Markov permettent d'économiser 6g/km de CO_2 sur la partie urbaine. Sur la partie extra-urbaine les prédictions normalement distribuées présentent un meilleur résultat avec 1g/km de CO_2 de moins. Les prédictions en chaînes de Markov paraissent alors plus adaptées aux parties urbaines du trajet. Par contre, même si les émissions sur la partie extra-urbaine sont sensiblement équivalentes, les prédictions normalement distribuées donnent une meilleure précision sur l'état de charge final.

Les deux modèles probabilistes étudiés pour modéliser les prédictions sont adaptés chacun à un type de trajet. Sur la partie urbaine du trajet la prédiction en chaîne de Markov est plus efficace, tandis que la prédiction normalement distribuée est plus adaptée à la partie extra-urbaine. Cela peut confirmer une idée intuitive sur l'analyse du style de conduite généralement observé, car un trajet extra-urbain occasionne des variations de couples et vitesses qui sont

raisonnablement distribuées autour du régime de croisière, alors que pour une conduite urbaine les accélérations/décélérations sont plus nombreuses et non maîtrisées, c'est-à-dire plus largement distribuées.

Dans la partie suivante les trajets Horscha seront simulés avec l'Audi A2 en utilisant le PMP probabiliste avec prédiction en chaînes de Markov sur la partie urbaine, et avec des prédictions normalement distribuées sur la partie extra-urbaine.

4.3 Comparaison des méthodes : Déterministe versus Probabiliste

Le PMP energy management probabiliste permet de réaliser un contrôle optimal sur le plus grand horizon de prédiction que le modèle probabiliste utilisé. Le PMP energy management déterministe considère que les prédictions sont complètement fiables et ne prend pas en compte la très probable incertitude des prédictions. Dans cette partie, les résultats des trois Simulations des cycles Horscha sont comparés :

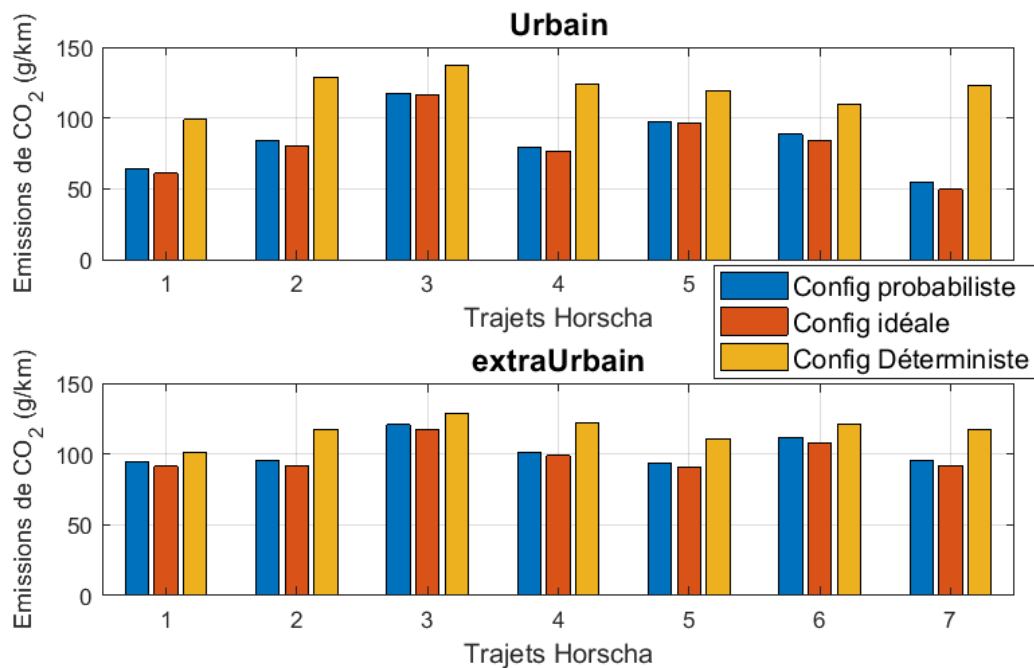


FIGURE 4.24 – Comparaison des émissions de CO_2 sur les parties urbaines et extra-urbaines des trajets Horscha : Déterministe idéal versus Déterministe versus Probabiliste

- Configuration idéale : Le cycle est simulé avec le PMP energy management déterministe, avec l'hypothèse du chapitre précédent, où les prédictions correspondent aux demandes de puissance réelles.
- Configuration déterministe : Le cycle est simulé avec le PMP energy management

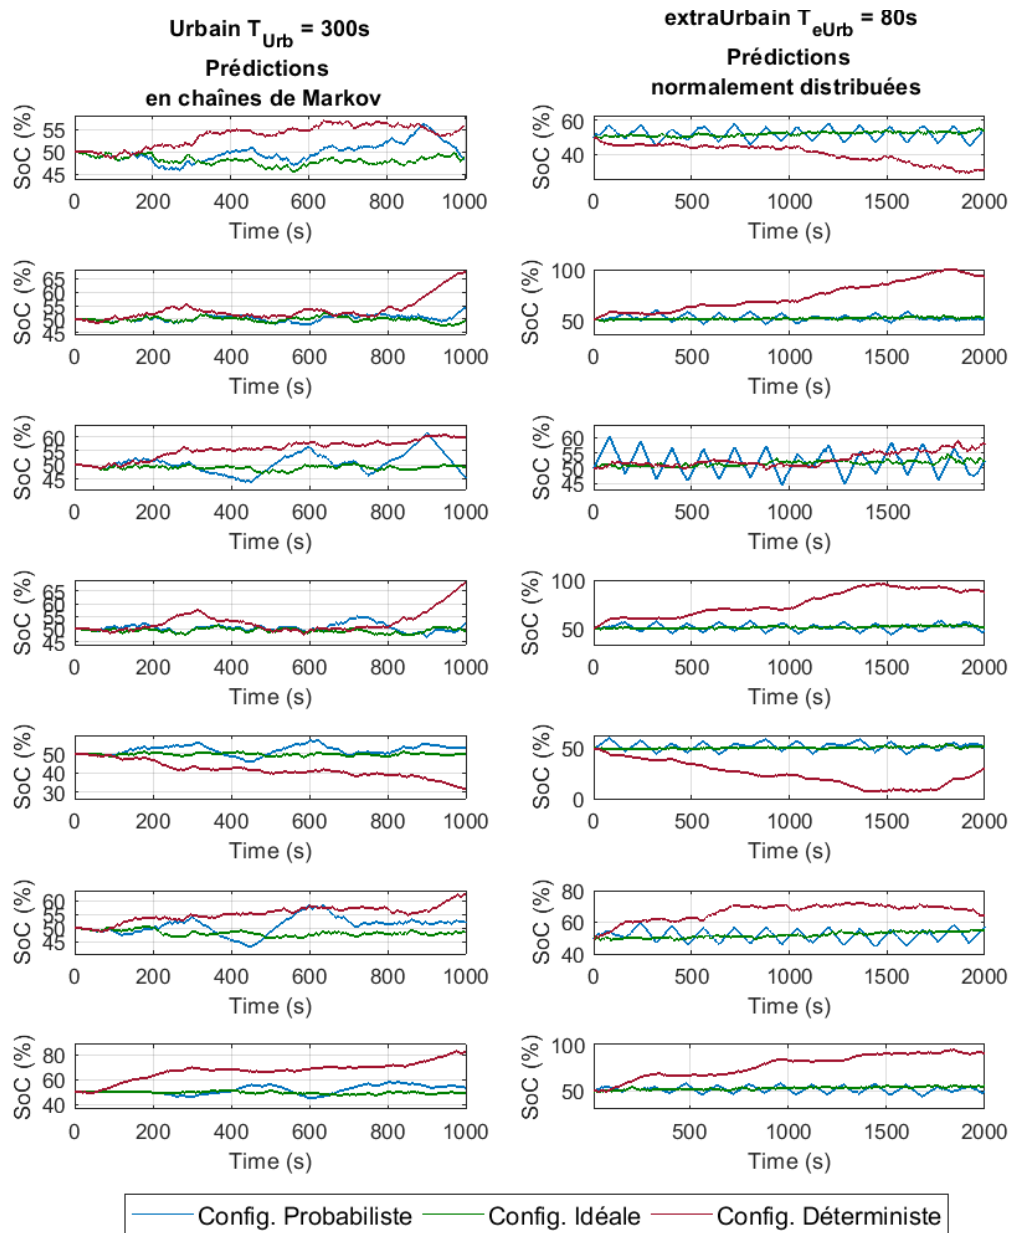


FIGURE 4.25 – Comparaison des trajectoires de SoC sur les trajets Horscha : Déterministe idéal versus Déterministe versus Probabiliste

déterministe, en condition de conduites réelles. La prédiction correspond à un premier enregistrement Horscha, différent du cycle parcouru.

- Configuration probabiliste : Le cycle est simulé avec Le PMP energy management probabiliste avec distributions normales sur la partie extra-urbaine et avec prédictions en chaînes de Markov sur la partie urbaine.

L'horizon de prédiction utilisé est le même pour les trois Simulations. Pour la partie ur-

baine il vaut $T_{Urb} = 150s$ et dans la partie extra-urbaine $T_{eUrb} = 80s$. Pour chaque trajet enregistré, l'enregistrement précédent est considéré comme prédiction pour le PMP déterministe. 7 trajets sont alors simulés, les 7 autres faisant office de prédiction.

La Figure 4.25 illustre les trajectoires de SoC sur chacun des trajets Horsch. Pour les 7 trajets simulés, l'utilisation du PMP Energy management probabiliste permet de s'approcher de la valeur visée de SoC , contrairement au PMP déterministe qui s'écarte à cause de sa prédiction imprécise. Cet écart est d'autant plus visible lors de la partie extra-urbaine où les puissances demandées sont plus importantes. Même en présence d'oscillations avec le PMP probabiliste, la méthode arrive à s'approcher de la valeur visée, par rapport à l'algorithme déterministe. Du point de vue des émissions de CO_2 , comme le montre la Figure 4.24, la configuration idéale donne évidemment la meilleure émission. L'utilisation du PMP probabiliste permet d'approcher la valeur de la configuration idéale, par rapport à la configuration déterministe.

4.4 Conclusions

L'algorithme PMP Energy management probabiliste permet alors d'anticiper les incertitudes sur les prédictions. A l'aide des modèles probabilistes, il réduit l'erreur sur l'état de charge final par rapport à l'algorithme déterministe. Sur la partie urbaine du trajet, les valeurs de vitesse sont dispersées, où la vitesse peut varier de $0km/h$ à l'arrêt jusqu'à $50km/h$. Sur la partie extra-urbaine on roule généralement à la vitesse limite, les valeurs de la vitesse sont alors moins dispersées et sont concentrées autour de la vitesse limite. Ceci peut expliquer les meilleurs résultats obtenus avec les prédictions normalement distribuées sur la partie extra-urbaine. Néanmoins, les oscillations de SoC persistent sur cette partie du trajet. Les distributions normales utilisées lors des simulations sont issues de 14 enregistrements, mais la précision de ses distributions peut être augmentée en utilisant plus d'enregistrements, ce qui permettrait de réduire les erreurs en SoC à chaque horizon de prédiction, et donc l'amplitude des oscillations. D'ailleurs, la chaîne de Markov utilisée à été construite avec une discrétisation de l'espace des prédictions en 50×50 points. En augmentant ce nombre de points, il devrait être possible d'augmenter la précision du modèle et donc d'espérer de meilleurs résultats. Par contre, notons que l'utilisation de la chaîne de Markov entraîne un temps de calcul plus conséquent ($10min$ sur la partie extra-urbaine) par rapport à l'utilisation des distributions normales ($2min$ sur la partie extra-urbaine). Ceci est dû aux simplifications de calcul qu'apporte la distribution normale. De manière générale, la méthodologie du PMP probabiliste peut être utilisée avec tout type de modèle probabiliste fait sur les prédictions. En prenant un modèle plus représentatif les résultats obtenus en terme d'erreur en état de charge de la batterie, et donc en consommation et émission de CO_2 , peuvent être améliorés.

Conclusion et perspectives

Le concept de *Internet of things* ouvre aujourd'hui la porte à une multitude d'informations en temps réel, pour tous les types de système. Dans le domaine automobile, mis à part les services de télécommunication, la connectivité du véhicule est aujourd'hui utilisée essentiellement dans la navigation et l'optimisation en temps des trajets. Nous avons exposé dans cette thèse comment la connectivité permettrait d'optimiser l'utilisation de l'énergie électrique dans un véhicule hybride électrique. La stratégie d'utilisation des 2 moteurs d'un véhicule hybride (*Energy management*) a un impact considérable sur la consommation de carburant et donc sur les émissions de CO_2 . Les méthodes existantes d'*Energy management* visant une optimisation basée sur un modèle de véhicule se retrouvent devant deux difficultés. La première est la difficulté de la résolution rigoureuse du problème d'optimisation une fois formulé, ce qui résulte en des algorithmes très coûteux en temps de calculs et inadaptés à l'implémentation en temps réel. La deuxième difficulté est l'anticipation du futur comportement du conducteur. La littérature sur les méthodes d'*Energy management* se divisent en deux catégories : une première qui abandonne l'aspect temps réel de la problématique et qui suppose connaître parfaitement le comportement du conducteur, dans le but de trouver des solutions globales et ainsi de pouvoir les caractériser. La deuxième catégorie contient les méthodes destinées à l'implémentation en temps réel et qui font des concessions sur l'optimalité de la solution afin d'obtenir une solution réalisable. Cette thèse propose une méthode qui utilise les données issues de la connectivité des véhicules pour obtenir des informations sur le comportement du conducteur, et les utiliser dans une résolution rigoureuse du problème d'*Energy management* formulé en problème de contrôle optimal.

Nous avons modélisé le problème d'*Energy management* par un problème de contrôle optimal, où l'on cherche à ramener l'état de charge de la batterie de son état initial à un état final donné en minimisant l'intégrale de la puissance thermique de l'ICE (proportionnelle à la masse de carburant consommée) sur la durée du trajet futur prédit. La méthode de résolution que nous proposons dans cette thèse se base sur le *Principe du Minimum de Pontryagin*, un théorème mathématique qui donne les conditions nécessaires d'optimalité d'un problème de contrôle optimal. L'énoncé de ce théorème appliqué à notre problématique permet d'obtenir deux avantages. Tout d'abord, on ramène notre optimisation sur un intervalle temporel à une optimisation instantanée. En effet, la méthode que nous proposons consiste à minimiser à chaque instant l'Hamiltonien qui est calculable en fonction des états du véhicule qui sont accessibles en temps réel. Ensuite, l'utilisation du PMP permet de ramener les incertitudes de la prédiction sur l'état de charge final sans directement affecter l'optimalité en terme de consommation. Evidemment, l'erreur qu'induit l'imprécision des prédictions sur l'état de charge se reflète indirectement sur la consommation. Néanmoins, la méthode que nous proposons, la *PMP Energy management*, suggère d'anticiper les imprécisions des prédictions en jouant sur un seul paramètre, la valeur initiale du co-état.

Si on fait abstraction de l'incertitude des prédictions, l'utilisation du PMP pour résoudre le problème de contrôle optimal d'*Energy Management* semble permettre de s'approcher de

l'optimum global de ce problème. Les résultats du *PMP Energy Management* obtenus par les tests numériques du chapitre 3 s'approchent dans tous les cas de la solution de référence donnée par un algorithme de programmation dynamique. Dans certains cas, la solution de référence est même atteinte. Ceci peut être expliqué par l'éventuelle convexité de la fonction objectif. Nous avons aussi étudié l'impact d'une simplification du modèle de la batterie sur les résultats. Il s'avère que pour des batteries à capacité énergétique assez élevée, utiliser un modèle de batterie à tension constante n'a pas d'impact significatif sur les résultats du *PMP Energy Management*. Dans des simulations plus proches du contexte véhicule, où le modèle complet de la Ford Focus GTC2 et l'interface de simulation ont été fournis par Continental, les différences entre le modèle utilisé par l'optimisation et le modèle du véhicule simulé altèrent le résultat en état de charge final. Cependant, en comparaison avec la méthode la plus performante développée par Continental, le *PMP Energy Management* obtient de meilleurs résultats en émission de CO_2 . Les solutions obtenues par le *PMP Energy Management* tendent à utiliser plus d'énergie électrique, ce qui décharge plus la batterie durant la trajectoire, en anticipation de futures recharges que permet le freinage régénératif. Ce qui correspond à l'aspect prédictif d'une méthode qui utilise des informations sur le futur trajet.

Les incertitudes des prédictions ne peuvent cependant pas être négligées et la version déterministe du *PMP Energy Management* n'est pas adaptée à l'utilisation en temps-réel. Si la connectivité donne une prédiction fixe du trajet futur, le risque de décharger ou surcharger la batterie est important. Ceci influence les émissions de CO_2 du véhicule. Le *PMP Energy Management probabiliste* anticipe alors ces incertitudes sur les prédictions en considérant les prédictions comme des variables aléatoires. En utilisant le PMP comme approche de résolution, les incertitudes des prédictions sont ramenées sur l'état de charge final. Notre méthode probabiliste s'appuie alors sur les distributions de probabilités des prédictions pour calculer la distribution de probabilités de l'état de charge final. Le *PMP Energy Management probabiliste* donne alors la solution qui maximise la probabilité d'obtenir l'état de charge final souhaité. La méthode dépend de la distribution de probabilités des prédictions. La précision de la distribution de probabilités en terme de représentativité des demandes du conducteur permet à notre méthode probabiliste d'être plus précise en état de charge final sur de plus longs horizons de prédiction que ceux de la littérature. Nous avons d'abord modélisé les prédictions par des variables aléatoires à distribution normale en chaque instant. Grâce aux propriétés de linéarité de la distribution normale, les calculs sont plus rapides. Nous avons aussi étudié des prédictions modélisées par chaînes de Markov. Au travers des simulations sur des enregistrements de trajets réels, la distribution normale s'est montrée plus efficace sur les parties extra-urbaines alors que les chaînes de Markov ont donné de meilleurs résultats sur les parties urbaines. La méthode du *PMP Energy Management probabiliste* peut être utilisée avec n'importe quel autre modèle probabiliste décrivant les distributions de probabilités des prédictions. Nous pouvons étudier les résultats de la méthode en utilisant par exemple de l'intelligence artificielle pour mieux définir la distribution de probabilités des prédictions.

Les travaux exposés dans cette thèse ont mené à la publication de trois articles dans des conférences internationales : [94],[95],[96]. Les nombreux tests numériques exposés ont montré un potentiel de gain en émission de CO_2 . Par rapport à la méthode CostBased par exemple, nous avons un gain de $1g/km$ de CO_2 . Si l'on ramène ce petit gramme au nombre

de véhicules hybrides vendus, multiplié par le nombre de kilomètres parcourus par an, on s'aperçoit que la méthode proposée peut avoir un impact considérable sur les émissions de CO_2 provenant du domaine du transport automobile... en attendant des sources d'énergie propre et une technologie permettant l'essor des véhicules 100% électriques de la conception à l'utilisation.

Cycles et trajets

Le cycle NEDC, acronyme pour *New European Driving Cycle* (nouveau cycle Européen de conduite), est un cycle d'homologation de $11km$ utilisé depuis 1973 en Europe, pour mesurer les émissions de polluants et de CO_2 ainsi que les consommations des véhicules.

Le cycle WLTC, acronyme pour *Worldwide harmonized Light vehicles Test Cycle* (Cycle d'essai mondial harmonisé pour les voitures particulières et véhicules utilitaires légers), est un cycle d'homologation de $23km$ utilisé en Europe depuis Septembre 2017 en remplacement du cycle NEDC.

Le cycle JC08 est un cycle d'homologation Japonais (*Japanese Cycle*) de $8km$. Ce cycle représente une conduite avec un trafic congestionné incluant de fortes accélérations et décélérations.

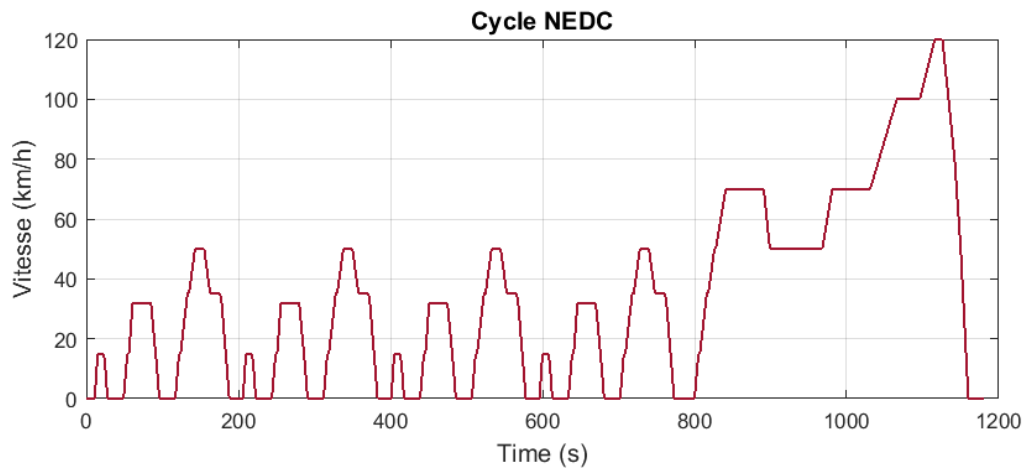

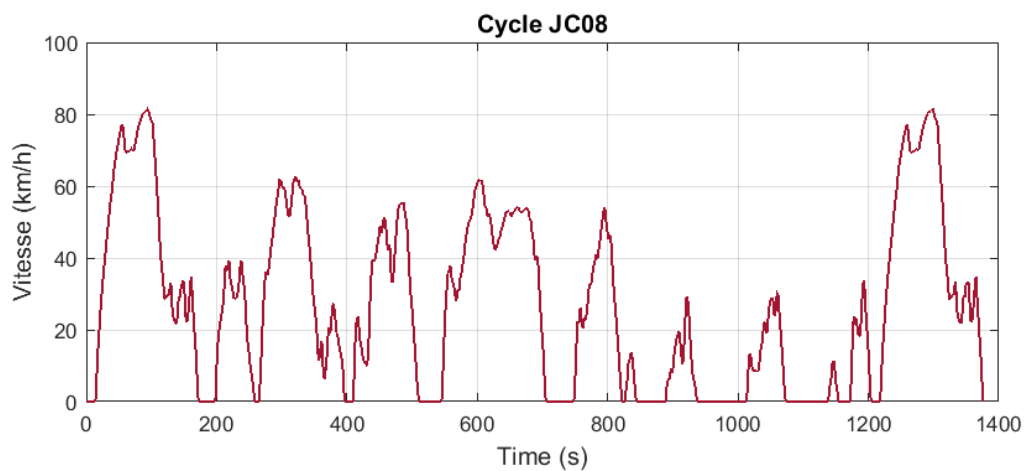
Le cycle RDE95 (Real Driving Emissions) est un cycle d'homologation des émissions de $12km$. Ce cycle représente une conduite agressive ou "sportive" avec des parties urbaines et extra-urbaines.




Le cycle Artemis n'est pas utilisé en tant que cycle d'homologation. Il est cependant utilisé par les constructeurs automobiles afin de mieux tester leur véhicules en conditions de conduite réelles. Le cycle Artemis utilisé dans la thèse est un cycle de $17km$ représentant les conditions de conduite réelle dans un milieu rural.


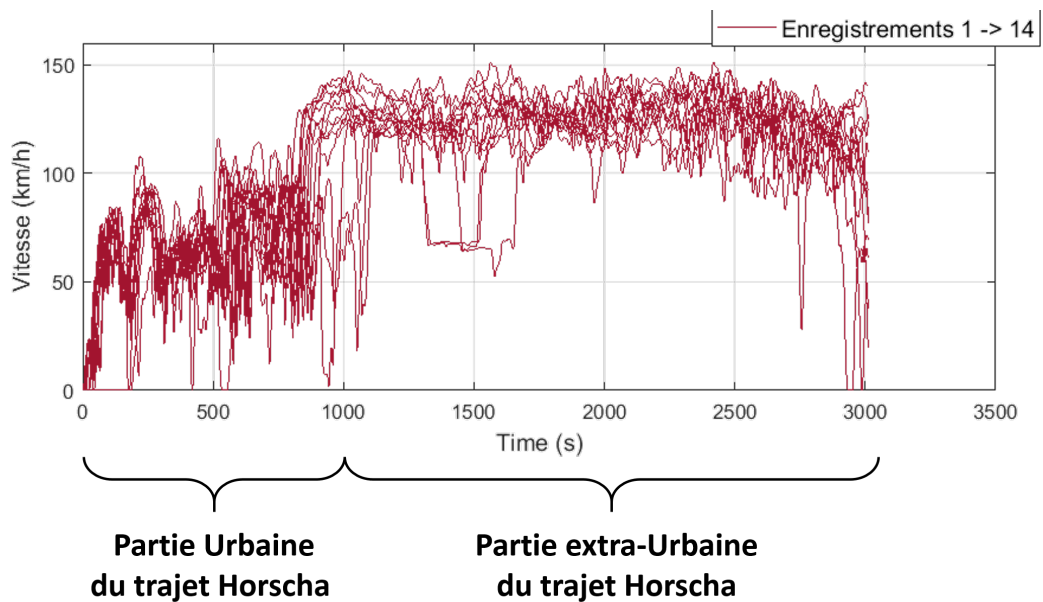
Le trajet RCC (*Regensburg City Cycle*), a été enregistré par Continental dans la ville de Regensburg en Allemagne, avec la Ford Focus GTC2. C'est un cycle de $18km$ qui représente un parcours de ville.

Le trajet Falkenstein est un trajet extra-urbain qui a été enregistré par Continental avec la Ford Focus GTC2, aux alentours du village Falkenstein en Allemagne. C'est un trajet de $60km$.

Le trajet Horscha correspond au voyage entre le village d'Horscha et la ville de Dresden en Allemagne. Le trajet est de $100km$. Les 14 enregistrement ont été faits par l'*Institute of Automotive Mechatronics* de l'université de Dresden avec l'Audi A2 Hybrid.

FIGURE A.1 – Vitesse du véhicule en *km/h* lors du cycle NEDCFIGURE A.2 – Vitesse du véhicule en *km/h* lors du cycle WLTCFIGURE A.3 – Vitesse du véhicule en *km/h* lors du cycle JC08

FIGURE A.4 – Vitesse du véhicule en km/h lors du cycle RDE95FIGURE A.5 – Vitesse du véhicule en km/h lors du cycle ArtemisFIGURE A.6 – Vitesse du véhicule en km/h lors du trajet RCC

FIGURE A.7 – Vitesse du véhicule en *km/h* lors du trajet FalkensteinFIGURE A.8 – Vitesse du véhicule en *km/h* lors des 14 enregistrements du trajet Horscha

Modèle AMESim de la Ford Focus

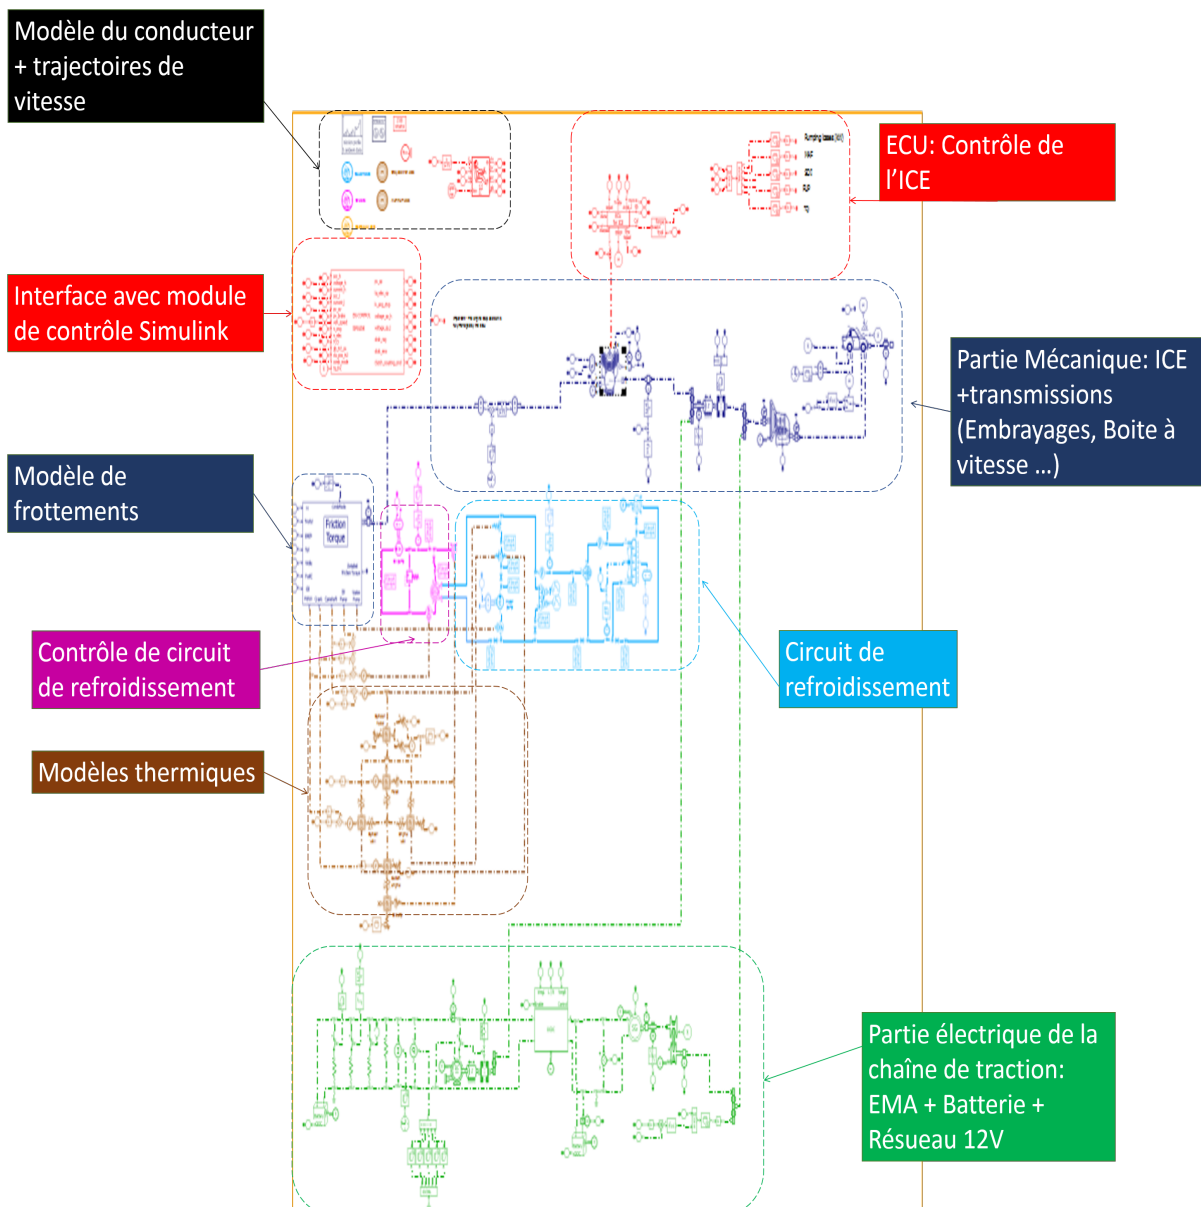


FIGURE B.1 – Schéma du Modèle de Continental sur le logiciel de simulations multi-physique AMESim de la Ford Focus GTC2.

Calcul d'émissions CO_2 équivalentes

Le calcul des émissions équivalentes de CO_2 d'un véhicule hybride se fait à partir de la masse de carburant consommée, ainsi que de la variation globale d'état de charge SoC sur le trajet. Notons $\Delta.SoC$ cette variation. L'équivalent de CO_2 est obtenu en additionnant l'émission de CO_2 équivalente à la masse de fuel M_{fuel} que nous notons $Eq_{fuel}^{CO_2}$, et l'émission équivalente à la variation d'état de charge de la batterie $\Delta.SoC$, que l'on note $Eq_{elec}^{CO_2}$. Ainsi, $Eq_{elec}^{CO_2}$ est négative si $\Delta.SoC$ est positive.

$Eq_{fuel}^{CO_2}$ est calculé en multipliant la masse de fuel consommée par le coefficient d'émissions de CO_2 par gramme de diesel $Coeff_{fuel} = 3.15$. $Eq_{elec}^{CO_2}$ est calculé en multipliant la variation d'énergie électrique (obtenue à partir de ΔSoC) par le coefficient d'émissions de CO_2 par kWh d'énergie électrique $Coeff_{elec} = 660.8g/kWh$.

La formule donnant l'émission équivalente d'un véhicule durant un trajet où il a consommé M_{fuel} grammes de carburant avec une variation globale ΔSoC d'état de charge de la batterie, est donnée par :

$$\begin{aligned}
 Eq_{CO_2} &= Eq_{fuel}^{CO_2} + Eq_{elec}^{CO_2} \\
 &= M_{fuel}Coeff_{fuel} - \frac{\Delta SoC}{Q_{max}V_{bat}}Coeff_{elec}
 \end{aligned}
 \tag{C.1}$$

Bibliographie

- [1] IEA, éd. *CO₂ Emissions from fuel combustion*. 2017. URL : <https://www.iea.org/publications/freepublications/publication/> (cf. p. 1).
- [2] SECTEN, éd. *Inventaire SECTEN 2017*. 2017. URL : <https://www.citepa.org/fr/activites/inventaires-des-emissions/secten> (cf. p. 2).
- [3] W.H. PATTON. « Motor for street cars ». In : *U.S Patent 409,116* (1889) (cf. p. 5).
- [4] G.W. HOBBS et B.G. ELLIOTT. « The Gasoline Automobile ». In : *New York : McGraw-Hill Book* (1920/1915) (cf. p. 5).
- [5] K. ERNST. *Cars of Futures Past – 1901 Lohner-Porsche Semper Vivus and Mixte*. Sous la dir. d’Hemmings DAILY. 2013. URL : <https://www.hemmings.com/blog/2013/08/15/cars-of-futures-past-1901-lohner-porsche-semper-vivus-and-mixte/> (cf. p. 5).
- [6] J. GRAHAME. « 1968 : AMC’s Amazing Amitron Electric Car ». In : *Retro Thing : Vintage Gadgets and Technology* (2008) (cf. p. 6).
- [7] J. GOODSTEIN. « Godfather of the hybrid ». In : *Engineering and Science. California Institute of Technology* (2008), p. 22,23 (cf. p. 6).
- [8] C.C. CHAN. « The state of the art of electric and hybrid vehicles ». In : *Proceedings of the IEEE* Volume : 90, Issue : 2 (2002), p. 247–275 (cf. p. 6, 7).
- [9] C.C. CHAN, A. BOUSCAYROL et K. CHEN. « Electric, Hybrid, and Fuel-Cell Vehicles : Architectures and Modeling ». In : *IEEE Transactions on Vehicular Technology* 59.2 (2010), p. 589–598 (cf. p. 6).
- [10] G. WU, X. ZHANG et Z. DONG. « Powertrain architectures of electrified vehicles : Review, classification and comparison ». In : *Journal of The Franklin Institute* 352 (2015), p. 425–448 (cf. p. 6).
- [11] A. PANDAY et H. OM-BANSAL. « A Review of Optimal Energy Management Strategies for Hybrid Electric Vehicle ». In : *International Journal of Vehicular Technology* 2014 (2014) (cf. p. 12, 14).
- [12] F.R. SALMASI. « Control Strategies for Hybrid Electric Vehicles : Evolution, Classification, Comparison, and Future Trends ». In : *IEEE Transactions on vehicular Technology* Vol. 56 (2007), p. 2393–2404 (cf. p. 12, 14, 15).
- [13] P. ZHANG, F. YAN et Ch. DU. « A comprehensive analysis of energy management strategies for hybrid electric vehicles based on bibliometrics ». In : *Renewable and Sustainable Energy Reviews* Vol. 48 (2015), p. 88–104 (cf. p. 14, 17).
- [14] M. MOHAMMADIAN et M.T BATHAEE. « Motion control for hybrid electric vehicle ». In : *Proceedings of the fourth international power electronics and motion control conference* Vol. 3 (2004), p. 1490–1494 (cf. p. 14).

- [15] M. EHSANI, Y. GAO, S.E. GAY et al. « Modern Electric, Hybrid Electric, and Fuel Cell Vehicles : Fundamentals, Theory, and Design ». In : *CRC press* (2004), p. 244–246 (cf. p. 14).
- [16] J-P. GAO, G-M.G. ZHU, E.G. STRANGAS et al. « Equivalent fuel consumption optimal control of a series hybrid electric vehicle ». In : *Proceedings of the Institution of Mechanical Engineers, Part D : Journal of Automobile Engineering Institution of Mechanical Engineers* (2006) (cf. p. 14).
- [17] Z.G. ZHAO, Z.P. YU, M.L. YIN et al. « Torque distribution strategy for single drive-shaft parallel hybrid electric vehicle ». In : *Proceedings of the IEEE intelligent vehicles symposium* (2009), p. 1350–1353 (cf. p. 14).
- [18] K.B. WIPKE, M.R. CUDDY et S.D. BURCH. « ADVISOR 2.1 : a user-friendly advanced powertrain simulation using a combined backward/forward approach ». In : *IEEE Transactions on Vehicular Technology* Vol. 48 (1999), p. 1751–1761 (cf. p. 14).
- [19] A. KONEV, L. LEZHNEV et I. KOLMANOVSKY. « Control strategy optimization for a series hybrid vehicle ». In : *SAE International* (2006) (cf. p. 14).
- [20] V.H. JOHNSON, K.B. WIPKE et D.J. RAUSEN. « HEV control strategy for realtime optimization off fuel economy and emissions ». In : *SAE Internation* (2000) (cf. p. 14).
- [21] M.H. HAJIMIRI et F.R. SALMASI. « A Predictive and Battery Protective Control Strategy for Series HEV ». In : *Journal of Asian Electric Vehicles* Vol. 6 (2008) (cf. p. 14).
- [22] A.M. PHILLIPS, M. JANKOVIC et K. BAILEY. « Vehicle system controller design for a hybrid electric vehicle ». In : *Proceedings of the IEEE International Conference on Control Applications* (2000), p. 297–302 (cf. p. 15).
- [23] H-D. LEE et S-K. SUL. « Fuzzy-logic-based torque control strategy for parallel-type hybrid electric vehicle ». In : *IEEE Transactions on Industrial Electronics* Vol. 45 (1998), p. 625–632 (cf. p. 15).
- [24] H-D. LEE, E-S. KOO, S-K. SUL et al. « Torque control strategy for a parallel-hybrid vehicle using fuzzy logic ». In : *IEEE Industry Applications Magazine* Vol. 6 (2000), p. 33–38 (cf. p. 15).
- [25] B.M. BAUMANN, G. WASHINGTON, B.C. GLENN et al. « Mechatronic design and control of hybrid electric vehicles ». In : *IEEE/ASME Transactions of Mechatronics* Vol. 5 (2000), p. 58–71 (cf. p. 15).
- [26] N.J. SCHOUTEN, M. SALMAN et N. KHEIR. « Fuzzy logic control for parallel hybrid vehicles ». In : *IEEE Transactions on Control Systems Technology* Vol. 10 (2002), p. 460–468 (cf. p. 15).
- [27] R. LANGARI et J-S. WON. « Intelligent energy management agent for a parallel hybrid vehicle—Part I ». In : *IEEE Transactions on Vehicles Technology* Vol. 54 (2005), p. 925–934 (cf. p. 15).
- [28] R. LANGARI et J-S. WON. « Intelligent energy management agent for a parallel hybrid vehicle—Part II ». In : *IEEE Transactions on Vehicles Technology* Vol. 54 (2005), p. 935–952 (cf. p. 15).

- [29] A. RAJAGOPALAN, G. WASHINGTON, G. RIZZONI et al. « Development of fuzzy logic control and advanced emissions modelling for parallel hybrid vehicles ». In : *The National Renewable Energy Laboratory* (2003) (cf. p. 15).
- [30] S. ICHIKAWA, Y. YOKOI, S. DOKI et al. « Novel energy management system for hybrid electric vehicles utilizing car navigation over a commuting route ». In : *Proceedings of The IEEE Intelligent Vehicle Symposium* (2004), p. 161–166 (cf. p. 15).
- [31] A. BOUKEHILI, Y.T. ZHANG, Q. ZHAO et al. « Hybrid vehicle power management modeling and refinement ». In : *International Journal of Automotive Technology* Vol. 13 (2012), p. 987–998 (cf. p. 16).
- [32] L. TRIBIOLI, M. BARBIERI, R. CAPATA et al. « A Real Time Energy Management Strategy for Plug-in Hybrid Electric Vehicles based on Optimal Control Theory ». In : *Energy Procedia* Vol. 45 (2014), p. 949–958 (cf. p. 16).
- [33] Y-J. HUANG, C-L. YIN et J-W. ZHANG. « Design of an energy management strategy for parallel hybrid electric vehicles using a logic threshold and instantaneous optimization method ». In : *International Journal of Automotive Technology* Vol. 10 (2009), p. 513–521 (cf. p. 16).
- [34] B. SKUGOR, J. DEUR, M. CIPEK et al. « Design of a power-split hybrid electric vehicle control system utilizing a rule-based controller and an equivalent consumption minimization strategy ». In : *Proceedings of the Institution of Mechanical Engineers, Part D : Journal of Automobile Engineering Institution of Mechanical Engineers* Vol. 228 (2014), p. 631–648 (cf. p. 16).
- [35] K. OH, J. MIN, D. CHOI et al. « Optimization of control strategy for a single-shaft parallel hybrid electric vehicle ». In : t. Vol. 221. 2007, p. 555–565 (cf. p. 17).
- [36] T. CHYUAN-YOW, H. YI-HSUAN, T. CHIEN-HSIUNG et al. « Parameters optimization for the energy management system of hybrid electric vehicle ». In : *Proceedings of the international society for optics and photonics* (2007) (cf. p. 17).
- [37] R. ZHANG et Y. CHEN. « Control of hybrid dynamical systems for electric vehicles ». In : *Proceedings of the American Control Conference* Vol. 4 (2001), p. 2884–2889 (cf. p. 17).
- [38] W. GAO et S.K. PORANDLA. « Design optimization of a parallel hybrid electric powertrain ». In : *IEEE Vehicle Power and Propulsion Conference* (2005) (cf. p. 17).
- [39] M. MONTAZERI-GH, A. POURSAMAD et B. GHALICHI. « Application of genetic algorithm for optimization of control strategy in parallel hybrid electric vehicles ». In : *Journal of the Franklin Institute* Vol. 343 (2006), p. 420–435 (cf. p. 17).
- [40] Z. WANG, B. HUANG, Y. XU et al. « Optimization of Series Hybrid Electric Vehicle Operational Parameters By Simulated Annealing Algorithm ». In : *IEEE International Conference on Control and Automation* (2007), p. 1536–1541 (cf. p. 17).
- [41] S. CAUX, D. WANDERLEY-HONDA, D. HISSEL et al. « On-line energy management for HEV based on Particle Swarm Optimization ». In : *IEEE Vehicle Power and Propulsion Conference* (2010), p. 1–6 (cf. p. 17).

- [42] J. WU, C.H. ZHANG et N.X. CUI. « PSO algorithm-based parameter optimization for HEV powertrain and its control strategy ». In : *International Journal of Automotive Technology* Vol .9 (2008), p. 53–59 (cf. p. 17).
- [43] R.E. BELLMAN. *Dynamic Programming*. Dover Books on Computer Science Series. Dover Publications, 2003 (cf. p. 18).
- [44] D.P. BERTSEKAS. *Dynamic Programming and Optimal Control*. 3rd. T. Vol. 1. Belmont, MA, USA : Athena Scientific, 1995 (cf. p. 18).
- [45] S.E. LYSHEVSKI et C. YOKOMOTO. « Control of hybrid-electric vehicles ». In : *Proceedings of the American Control Conference* (1998) (cf. p. 20).
- [46] C-C. LIN, H. PENG, J.W. GRIZZLE et al. « Power management strategy for a parallel hybrid electric truck ». In : *IEEE Transactions on Control Systems Technology* Vol. 11 (2003), p. 839–849 (cf. p. 20).
- [47] D. BIANCHI, L. ROLANDO, L. SERRAO et al. « A Rule-Based Strategy for a Series/Parallel Hybrid Electric Vehicle : An Approach Based on Dynamic Programming ». In : *ASME 2010 Dynamic Systems and Control Conference* Vol. 1 (2010), p. 507–514 (cf. p. 20).
- [48] Y-B. YU, Q-N. WANG, H-T. MIN et al. « Control strategy optimization using dynamic programming method for synergic electric system on hybrid electric vehicle ». In : *Natural Science* Vol. 1 (2009), p. 222–228 (cf. p. 20).
- [49] L. GUZZELLA et A. SCIARRETTA. *Vehicle Propulsion Systems*. T. Vol. 1. Berlin, Germany : Springer, 2013 (cf. p. 20).
- [50] Z. CHEN et C.C. MI. « An adaptive online energy management controller for power-split HEV based on Dynamic Programming and fuzzy logic ». In : *Proceedings IEEE Vehicle Power and Propulsion Conference* (2009), p. 335–339 (cf. p. 20).
- [51] G.Q. AO, J.X. QIANG, Z. HU et al. « Exploring the fuel economy potential of ISG Hybrid electric vehicles through dynamic programming ». In : *International Journal of Automotive Technology* Vol. 8 (2007), p. 781–790 (cf. p. 20).
- [52] L.S. PONTRYAGIN. *Mathematical Theory of Optimal Processes*. Classics of Soviet Mathematics. Taylor & Francis, 1987 (cf. p. 20).
- [53] S. DELPRAT, J. LAUBER, T.M. GUERRA et al. « Control of a parallel hybrid powertrain : optimal control ». In : *IEEE Transactions on Vehicular Technology* Vol. 53 (2004), p. 872–881 (cf. p. 22).
- [54] T.H. PHAM, J.T.B.A. KESSELS, P.P.J. VANDENBOSCH et al. « On-line energy and Battery Thermal Management for hybrid electric heavy-duty truck ». In : *American Control Conference* (2013), p. 710–715 (cf. p. 22).
- [55] J.T.B.A. KESSELS, M.W.T. KOOT, P.P.J. VANDENBOSCH et al. « Online Energy Management for Hybrid Electric Vehicles ». In : *IEEE Transactions on Vehicular Technology* Vol. 57 (2008), p. 3428–3440 (cf. p. 22).
- [56] H. YU, M. KUANG et M. MCGEE. « Trip-Oriented Energy Management Control Strategy for Plug-In Hybrid Electric Vehicles ». In : *IEEE Transactions on Control Systems Technology* Vol. 22 (2014), p. 1323–1336 (cf. p. 22).

- [57] J. JEONG, D. LEE, N. KIM et al. « Fuel economy analysis of a parallel hybrid bus using the optimal control theory ». In : *Proceedings IEEE Vehicle Power and Propulsion Conference* (2011), p. 1–5 (cf. p. 22).
- [58] S. KERMANI, R. TRIGUI, S. DELPRAT et al. « PHIL Implementation of Energy Management Optimization for a Parallel HEV on a Predefined Route ». In : *IEEE Transactions on Vehicular Technology* Vol. 60 (2011), p. 782–792 (cf. p. 22).
- [59] N. KIM, S.W. CHA et H. PENG. « Optimal equivalent fuel consumption for hybrid electric vehicles ». In : *IEEE Transactions on Control Systems Technology* Vol. 20 (2012), p. 817–825 (cf. p. 22).
- [60] R. RAZAVIAN, N.L. AZAD et J. MCPHEE. « On real-time optimal control of a series Hybrid Electric Vehicle with an ultra-capacitor ». In : *American Control Conference* (2012), p. 547–552 (cf. p. 22).
- [61] N. KIM, S. CHA et H. PENG. « Optimal Control of Hybrid Electric Vehicles Based on Pontryagin’s Minimum Principle ». In : *IEEE Transactions on Control Systems Technology* Vol. 19 (2011), p. 1279–1287 (cf. p. 23).
- [62] G. PAGANELLI, T.M. GUERRA, S. DELPRAT et al. « Simulation and assessment of power control strategies for a parallel hybrid car ». In : *Proceedings of the Institution of Mechanical Engineers, Part D : Journal of Automobile Engineering* (2000), p. 705–717 (cf. p. 23).
- [63] L. SERRAO, S. ONORI et G. RIZZONI. « ECMS as a realization of Pontryagin’s minimum principle for HEV control ». In : *American Control Conference* (2009), p. 3964–3969 (cf. p. 23).
- [64] G. PAGANELLI, S. DELPRAT, T.M. GUERRA et al. « Equivalent consumption minimization strategy for parallel hybrid powertrains ». In : *IEEE 55th Vehicular Technology Conference*. Vol. 4 (2002), p. 2076–2081 (cf. p. 23).
- [65] D. SINOQUET, G. ROUSSEAU et Y. MILHAU. « Design optimization and optimal control for hybrid vehicles ». In : *Optimization and Engineering* Vol. 12 (2011), p. 199–213 (cf. p. 23).
- [66] J. PARK et J.H PARK. « Development of equivalent fuel consumption minimization strategy for hybrid electric vehicles ». In : *International Journal of Automotive Technology* Vol. 13 (2012), p. 835–843 (cf. p. 23).
- [67] L. LI, H. HUANG, J. LIAN et al. « Research of Ant Colony Optimized Adaptive Control Strategy for Hybrid Electric Vehicle ». In : *Mathematical Problems in Engineering* Vol. 2014 (2014), p. 835–843 (cf. p. 23).
- [68] M. KHODABAKHSHIAN, L. FENG et J. WIKANDER. « Improving fuel economy and robustness of an improved ECMS method ». In : 2013, p. 598–603 (cf. p. 23).
- [69] A. SCIARRETTA, M. BACK et L. GUZZELLA. « Optimal control of parallel hybrid electric vehicles ». In : t. Vol. 12. 2004, p. 352–363 (cf. p. 23).
- [70] T. VAN-KEULEN, B. DE-JAGER, A. SERRARENS et al. « Optimal Energy Management in Hybrid Electric Trucks Using Route Information ». In : *Oil Gas Science Technology – Rev. IFP* Vol. 65 (2009), p. 103–113 (cf. p. 23).

- [71] R. SHANKAR, J. MARCO et F. ASSADIAN. « The Novel Application of Optimization and Charge Blended Energy Management Control for Component Downsizing within a Plug-in Hybrid Electric Vehicle ». In : *Energies* Vol. 5 (2012), p. 4892–4923 (cf. p. 23).
- [72] X. YE, Z. JIN, X. HU et al. « Modeling and control strategy development of a parallel hybrid electric bus ». In : *International Journal of Automotive Technology* Vol. 14 (2013), p. 971–985 (cf. p. 23).
- [73] J. LIU et H. PENG. « Control optimization for a power-split hybrid vehicle ». In : *American Control Conference* (2006), p. 466–471 (cf. p. 23).
- [74] D. PEI et M.J. LEAMY. « Dynamic Programming-Informed Equivalent Cost Minimization Control Strategies for Hybrid-Electric Vehicles ». In : *Journal of Dynamic Systems, Measurement, and Control* Vol. 135 (2013) (cf. p. 23).
- [75] B. GENG, J.K. MILLS et Sun D. « Energy Management Control of Microturbine-Powered Plug-In Hybrid Electric Vehicles Using the Telemetry Equivalent Consumption Minimization Strategy ». In : t. Vol. 60. 2011, p. 4238–4248 (cf. p. 24).
- [76] C. MUSARDO, G. RIZZONI, Y. GUEZENNEC et al. « A-ECMS : An Adaptive Algorithm for Hybrid Electric Vehicle Energy Management ». In : *European Journal of Control* Vol. 11 (2005), p. 509–524 (cf. p. 24).
- [77] E.F. CAMACHO et C. BORDONS. *Model Predictive control, Advanced Textbooks in Control and Signal Processing*. 2nd. New York, NY, USA : Springer-Verlag, 2007 (cf. p. 24, 25).
- [78] H. BORHAN, A. VAHIDI, A.M. PHILLIPS et al. « MPC-Based Energy Management of a Power-Split Hybrid Electric Vehicle ». In : *IEEE Transactions on Control Systems Technology* Vol. 20 (2012), p. 593–603 (cf. p. 25).
- [79] B. SAMPATHNARAYANAN, L. SERRAO, S. ONORI et al. « Model Predictive Control as an Energy Management Strategy for Hybrid Electric Vehicles ». In : *Dynamic Systems and Control Conference* Vol. 2 (2009), p. 249–256 (cf. p. 25).
- [80] T.S. KIM, C. MANZIE et R. SHARMA. « Model predictive control of velocity and torque split in a parallel hybrid vehicle ». In : *IEEE International Conference on Systems, Man and Cybernetics* (2009), p. 2014–2019 (cf. p. 25).
- [81] H.A. BORHAN, C. ZHANG, A. VAHIDI et al. « Nonlinear Model Predictive Control for power-split Hybrid Electric Vehicles ». In : *IEEE Conference on Decision and Control* (2010), p. 4890–4895 (cf. p. 25).
- [82] L. JOHANNESSON, S. PETTERSSON et B. EGARDT. « Predictive energy management of a 4QT series-parallel hybrid electric bus ». In : *Control Engineering Practice* Vol. 17 (2009), p. 1440–1453 (cf. p. 25).
- [83] L. FU, Ü.Ö. ZGÜNER, P. TULPULE et al. « Real-time energy management and sensitivity study for hybrid electric vehicles ». In : *Proceedings of the 2011 American Control Conference* (2011), p. 2113–2118 (cf. p. 25).
- [84] G. RIPACCIOLI, D. BERNARDINI, S. DI-CAIRANO et al. « A stochastic model predictive control approach for series hybrid electric vehicle power management ». In : *American Control Conference* (2010), p. 5844–5849 (cf. p. 25).

-
- [85] S. DI-CAIRANO, D. BERNARDINI, A. BEMPORAD et al. « Stochastic MPC With Learning for Driver-Predictive Vehicle Control and its Application to HEV Energy Management ». In : *IEEE Transactions on Control Systems Technology* Vol. 22 (2014), p. 1018–1031 (cf. p. 25).
- [86] S. KERMANI, S. DELPRAT, T.M. GUERRA et al. « Predictive energy management for hybrid vehicle ». In : *Control Engineering Practice* Vol. 20 (2012), p. 408–420 (cf. p. 25).
- [87] Q. ZHANG, W. DENG et G. LI. « Stochastic Control of Predictive Power Management for Battery/Supercapacitor Hybrid Energy Storage Systems of Electric Vehicles ». In : *IEEE Transactions on Industrial Informatics* (2017) (cf. p. 25, 27).
- [88] S. XIE, H. HE et J. PENG. « An energy management strategy based on stochastic model predictive control for plug-in hybrid electric buses ». In : *Applied Energy* Vol. 196 (2017), p. 279–288 (cf. p. 25, 27).
- [89] A. SCIARRETTA et L. GUZZELLA. « Control of Hybrid Electric Vehicles ». In : *Ieee Control systems Magazine* (2007), p. 60–70 (cf. p. 26).
- [90] H.A. DAVID et H.N. NAGARAJA. *Order Statistics*. Wiley Series in Probability and Statistics. Wiley, 2004 (cf. p. 46).
- [91] MATLAB. *R2017b*. Natick, Massachusetts : The MathWorks Inc., 2017 (cf. p. 47).
- [92] E. TRELAT. *Contrôle optimal : théorie et applications*. Mathématiques Concrètes. Vuibert, 2005 (cf. p. 50).
- [93] L. MAZLIAK, P. PRIOURET et P BALDI. *Martingales Et Chaînes De Markov*. Editions Hermann, 1998 (cf. p. 98).
- [94] M. SANS et H. IDRISSEI-HASSANI-AZAMI. « Connected optimal predictive control for hybrid vehicles ». In : *Proceedings of the 2016 International Conference on Electrical Systems for Aircraft, Railway, Ship Propulsion and Road Vehicles and International Transportation Electrification Conference* (2016) (cf. p. 112).
- [95] H. IDRISSEI-HASSANI-AZAMI, S. CAUX, F. MESSINE et al. « Optimal Control for Energy Management of Connected Hybrid Electrical Vehicles : Predictive Connectivity Compared to an Adaptive Algorithm ». In : *Proceedings of the 4th International Conference on Vehicle Technology and Intelligent Transport Syst* (2018), p. 261–268 (cf. p. 112).
- [96] H. IDRISSEI-HASSANI-AZAMI, S. CAUX, F. MESSINE et al. « Probabilistic Optimal Control for Energy Management of Connected Hybrid Electrical Vehicles ». In : *Proceedings of the 2018 International Symposium on Power Electronics, Electrical Drives, Automation and Motion* (2018) (cf. p. 112).

Résumé — Le domaine automobile a été l'un des secteurs les plus émetteurs de CO₂ durant le dernier siècle. La solution envisagée, pour limiter les émissions de gaz à effet de serre des véhicules, est l'électrification de la chaîne de traction. Le véhicule hybride électrique présente le meilleur compromis pour relever les défis écologiques de l'industrie automobile. La chaîne de traction hybride électrique est composée de deux moteurs : un moteur à combustion interne, alimenté par du carburant, et un moteur électrique alimenté par une batterie. Ces deux moteurs doivent assurer la demande en puissance du conducteur. La répartition d'énergie entre les deux moteurs en temps réel se fait alors dans le but de minimiser la consommation de carburant. Cette thèse propose l'étude d'une méthode basée sur l'optimisation visant à rechercher la combinaison la plus efficace des deux moteurs. La méthodologie proposée cherche à concilier la recherche d'un optimum mathématique avec les contraintes du contexte temps-réel, en utilisant la théorie du contrôle optimal et le Principe du Maximum de Pontriaguine. La recherche d'un optimum mathématique suppose la connaissance d'une prédiction sur les demandes de puissances futures du conducteur. La méthode proposée se base sur la connectivité du véhicule (GPS intelligent e-Horizon par exemple) pour former cette prédiction. Dans un premier temps, la méthode est étudiée avec l'hypothèse d'une prédiction complètement fiable. A travers des comparaisons par simulation, nous avons pu constater que la méthode proposée peut atteindre l'optimum global que fournit un algorithme de programmation dynamique. En formulant le problème d'optimisation avec différentes hypothèses plus ou moins simplificatrices sur le modèle de la batterie, il s'avère que l'utilisation d'un modèle à tension constante n'altère pas l'optimalité de la solution, si la capacité énergétique de la batterie est assez élevée. L'utilisation de ce modèle simplifié permet d'accélérer les calculs, notamment quand il faudra prendre en compte les incertitudes des prédictions. Sous l'hypothèse de prédictions fiables, la méthode montrera une robustesse par rapport aux imprécisions du modèle utilisé. Pour prendre en compte les incertitudes de la prédiction des demandes de puissances du conducteur, le modèle proposé met en jeu des variables aléatoires. En utilisant le Principe du maximum de Pontriaguine, les incertitudes des prédictions n'affectent la consommation de carburant qu'à travers l'état de charge de la batterie en fin de parcours. Au lieu de valider une prédiction en la comparant aux valeurs réelles de la demande de puissance, l'incertitude est reportée sur l'énergie électrique et l'état de charge final de la batterie. Le modèle probabiliste des prédictions détermine la longueur de l'horizon de prédiction à utiliser. Des prédictions normalement distribuées, et des prédictions basées sur chaînes de Markov sont étudiées. Ces deux modèles permettent d'avoir des horizons de prédictions de 2-3 min sur lesquels notre méthode d'optimisation basée sur le contrôle optimale est appliquée en temps réel. La méthode probabiliste proposée est générale, et n'est pas limitée aux modèles probabilistes étudiés. A partir des principes exposés dans cette thèse, en augmentant la précision du modèle probabiliste des prédictions, il sera possible d'utiliser de plus grands horizons de prédictions, ce qui signifie de meilleures économies de carburant et moins d'émissions de CO₂.

Mots clés : Véhicules hybride électrique, Gestion de l'énergie, Connectivité des véhicules, Contrôle optimal, Principe du Minimum de Pontryagin, Optimisation prédictive.

Abstract — The automotive sector has been one of the most CO₂ emitting sectors over the past century. The solution considered, to limit vehicle emissions, is the electrification of the power train. The hybrid electric vehicle offers the best compromise to meet the ecological challenges of the automotive industry. The hybrid electric powertrain consists of two engines : an internal combustion engine, powered by fuel, and an electric motor powered by a battery. These two motors must ensure the driver's power demand. The energy is distributed between the two engines in real time in order to minimize fuel consumption. This thesis proposes the study of an optimization-based method to find the most efficient combination of the two engines. The proposed methodology seeks to reconcile the search for a mathematical optimum with the constraints of the real-time implementation, using the theory of optimal control, and the Pontryagin Maximum Principle. The search for a mathematical optimum presupposes the knowledge of a prediction on the driver's future power demands. These predictions can be formed through the vehicle's connectivity (intelligent GPS e-Horizon for example). First, the method is studied with the hypothesis of a completely reliable prediction. Through simulation comparisons, we have found that the proposed method can achieve the global optimum provided by a dynamic programming algorithm. By formulating the optimization problem with different simplifying assumptions on the battery model, it appears that the use of a constant voltage model does not alter the optimality of the solution, if the battery's energy capacity is high enough. The use of this simplified model may help to speed up calculations, especially when it is necessary to consider the uncertainties of predictions. Moreover, under the assumption of reliable predictions, the method shows robustness to the inaccuracies of the model used. To take into account the uncertainty of the power demands prediction, random variables are introduced in the model. Using the Pontryagin Maximum Principle theorem, the uncertainties of the predictions affect fuel consumption only through the battery's state of charge at the end of the trip. Instead of validating a prediction by comparing it with the actual values of the power demand, the uncertainty is transferred to the electrical energy and the final state of charge of the battery. The predictions probabilistic model determines the predictions horizon length. Normally distributed predictions, and predictions based on Markov chains are studied. These two models allow prediction horizons of 2-3 min over which our optimization method based on optimal control is applied in real time. The proposed probabilistic method is general and is not limited to the probabilistic models studied. Based on the principles outlined in this thesis, by increasing the accuracy of the predictions model, it will be possible to use larger prediction horizons, which means better fuel economy and lower CO₂ missions.

Keywords : Hybrid Electrical Vehicles, Energy management, Vehicles connectivity, Optimal control, Pontryagin's Minimum Principle, Prédictive Optimisation.
