



Stratégie intelligente de gestion du système énergétique global d'un véhicule hybride

Loïc Joud

► To cite this version:

Loïc Joud. Stratégie intelligente de gestion du système énergétique global d'un véhicule hybride. Energie électrique. Université Bourgogne Franche-Comté, 2018. Français. NNT : 2018UBFCK068 . tel-02158009

HAL Id: tel-02158009

<https://theses.hal.science/tel-02158009>

Submitted on 17 Jun 2019

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.



SPIM

Thèse de Doctorat



école doctorale **sciences pour l'ingénieur et microtechniques**
U N I V E R S I T É D E B O U R G O G N E

Stratégie intelligente de gestion du système énergétique global d'un véhicule hybride

 LOIC JOUD

SPIM

Thèse de Doctorat



école doctorale sciences pour l'ingénieur et microtechniques
UNIVERSITÉ DE BOURGOGNE

N° X X X

THÈSE présentée par

LOIC JOUD

pour obtenir le

Grade de Docteur de
l'Université de Bourgogne

Spécialité : **Mécanique et Énergétique**

Stratégie intelligente de gestion du système énergétique global d'un véhicule hybride

Unité de Recherche :
DRIVE EA1859

Soutenue publiquement le 15 octobre 2018 devant le Jury composé de :

ROCHDI TRIGUI	Rapporteur	Directeur de Recherche à l'IFSTTAR
FRANCOIS BADIN	Rapporteur	Directeur de Recherche à l'IFPEN
STÉPHANE CAUX	Président	Professeur à l'INP de Toulouse
PASCAL HIGELIN	Examineur	Professeur à l'Université d'Orléans
SERGE PÉLISSIER	Examineur	Directeur de Recherche à l'IFSTTAR
LUIS LE MOYNE	Directeur de thèse	Professeur à l'ISAT
DANIELA CHRENKO	Co-Directeur de thèse	Maître de conférence à l'UTBM
ALAN KÉROMNÈS	Co-Directeur de thèse	Maître de conférence à l'ISAT

REMERCIEMENTS

Je tiens tout d'abord à remercier Monsieur Luis Le Moyne qui m'a encadré tout au long de cette thèse.

Je remercie également Monsieur Bernard Delaporte, directeur du groupe Danielson, pour m'avoir proposé ce sujet de thèse puis permis de l'effectuer dans d'excellentes conditions au sein de son entreprise.

Je tiens à remercier tout particulièrement Daniela Chrenko, Alan Keromnes et Rui Da Silva Lourenco qui m'ont encadré et soutenu durant ces trois années. Qu'ils soient aussi remerciés pour leur disponibilité permanente et pour les nombreux encouragements qu'ils m'ont prodigués.

J'adresse tous mes remerciements à Monsieur Rochdi Trigui ainsi qu'à Monsieur François Badin, de l'honneur qu'ils m'ont fait en acceptant d'être rapporteurs de cette thèse.

J'exprime ma gratitude à Monsieur Stéphane Caux, à Monsieur Pascal Higelin, et à Monsieur Serge Pélissier, qui ont bien voulu donner de leur temps pour être examinateurs.

Je tiens à remercier tous les membres de Danielson pour leur accueil, leur bonne humeur et leur aide qu'ils ont su m'apporter au quotidien.

Je n'oublie pas non plus tous mes collègues doctorants sans qui l'aventure aurait été bien fade. Merci à Nans, Geremie, Richard, Ayoub, Michaël, Thomas, Rémy et tous les autres pour les échanges scientifiques et culturels, et surtout pour tous les moments de détente partagés au sein du labo.

Merci également à mes parents qui m'ont toujours soutenu dans mes études et encouragé pour ne jamais lâcher. Un retour dans la Drôme a toujours été source de remotivation, et ce, grâce aussi à mes grands parents, mon frère et mon oncle.

Et enfin un immense merci à Anne-Lise qui partage ma vie et qui me supporte au quotidien malgré mon caractère. Sans elle je n'écirai probablement pas ces lignes actuellement.

SOMMAIRE

Introduction générale	1
1 Définitions et stratégies de contrôle	5
1.1 Aspects technologiques	5
1.1.1 Type d'hybridation	5
1.1.2 Architecture	7
1.1.3 Répartition de puissance et autonomie électrique	9
1.2 Gestion énergétique du véhicule	11
1.2.1 Définitions	11
1.2.2 Conducteur	12
1.2.3 Cycles	16
1.2.4 Modélisation du véhicule	22
1.2.5 Critères adoptés pour évaluer les stratégies	24
1.3 Stratégies de contrôle	25
1.3.1 Méthodes basées sur des règles (branche b)	30
1.3.2 Méthodes d'optimisation (branche c)	40
1.3.2.1 Méthodes d'optimisation globale (branche g)	40
1.3.2.2 Méthodes d'optimisation en temps réel (branche f)	46
1.4 Conclusion	55
2 Analyse statistique des habitudes de conduite	57
2.1 Présentation du moyen d'essai et validation des mesures	58
2.1.1 Boîtier d'acquisition	58
2.1.2 Étude de la fréquence d'acquisition de l'accéléromètre	60
2.1.3 Répétabilité et reproductibilité des mesures	61
2.1.3.1 Accéléromètre	63
2.1.3.2 GPS	63
2.1.4 Conclusion sur le moyen d'essai	65
2.2 Analyse des trajets	71
2.2.1 Méthode d'inter-corrélation normalisée	71

2.2.2	Analyse statistique	71
2.2.3	Prédictibilité des trajets	73
2.3	Prédiction de cycle	76
2.3.1	Chaîne de Markov	76
2.3.2	Définition du cycle le plus représentatif	81
2.4	Conclusion	82
3	Modélisation du véhicule	83
3.1	Introduction	83
3.2	Présentation de la Noao et de sa stratégie de commande	84
3.3	Modélisation dynamique : la REM	84
3.4	Validation du modèle	93
3.5	Comparaison avec l'approche quasi-statique	99
3.6	Optimisation énergétique	107
3.6.1	Programmation Dynamique	107
3.6.1.1	Mise en équation du problème	107
3.6.1.2	Application de la DP du cycle le plus représentatif	108
3.6.2	Méthode d'optimisation temps réel	109
3.6.2.1	Principe de la résolution numérique par MPC	109
3.6.2.2	Présentation de la stratégie temps réel utilisée	110
3.6.2.3	Linéarisation du problème	110
3.6.2.4	Validation de la stratégie	114
3.6.3	Conclusion	119
	Conclusion générale	121

TABLE DES FIGURES

1	Objectif d'électrification du parc automobile suivant différents scénarios . . .	2
2	Objectif d'émissions de CO2 annuelles (à gauche) et cumulées (à droite) pour le siècle actuel	3
1.1	Différent types d'hybrides en fonction du niveau d'électrification	6
1.2	Classification des différentes architectures	8
1.3	Architecture de la Toyota Prius (tirée de les-moteurs-tpe.e-monsite.com) . .	9
1.4	Architecture de la DS5 Hybrid4 (tirée de www.moteurnature.com)	10
1.5	Analyse du niveau d'électrification par type d'hybridation	11
1.6	Analyse du niveau d'électrification suivant l'architecture du véhicule	12
1.7	Gestion énergétique du véhicule	13
1.8	Etude du cumul de consommation et d'émissions polluantes sur une dis- tance donnée pour différentes accélérations [36]	15
1.9	Cycle NEDC	18
1.10	Cycles standards américains	18
1.11	Cycles standards japonais	18
1.12	Cycles Artemis	19
1.13	Cycles réels considérés par certains auteurs pour la validation de la ges- tion énergétique	19
1.14	Relation entre durée, distance et heure de départ [91]	20
1.15	Prédictibilité du trajet suivant la position de départ [91]	21
1.16	Principe de fonctionnement d'une colonie de fourmis [117]	22
1.17	Flux d'informations dans un modèle dit "backward" [87]	23
1.18	Flux d'informations dans un modèle dit "forward" [87]	24
1.19	Principe de la programmation dynamique, exemple sur un cas de 4 étapes [86]	25
1.20	Principe du CD/CS et de la méthode optimale pour un PHEV (en rouge la courbe du CD/CS et en bleu la courbe de la méthode optimale)[40]	26
1.21	Présentation de toutes les stratégies employées [137]	28
1.22	Distribution quantitative des stratégies de gestion énergétique [137]	28
1.23	Distribution temporelle des stratégies de gestion énergétique [137]	29

1.24 Exemple de règle déterministe	30
1.25 Gestion énergétique de L. Tribioli et al. [123]	32
1.26 Gestion énergétique "multi-mode" de C. Lin et al. [66]	33
1.27 Comparaison entre la logique classique (à droite) et la logique floue (à gauche) pour la réponse à la question "la vitesse est elle élevée ?"	33
1.28 Principe de l'algorithme de reconnaissance de cycle [94]	34
1.29 Gestion énergétique avec DCRA de A. Ravey et al. [94]	35
1.30 Gestion énergétique avec basculement de règles [80]	36
1.31 Gestion énergétique de A. Neffati et al. [80]	38
1.32 IEMA architecture [129]	38
1.33 Temps caractéristiques [20]	38
1.34 Résultats de la simulation avec et sans IEMA [20]	39
1.35 Structure d'un algorithme génétique [31]	41
1.36 Exemple de matrice de probabilité de transition d'une chaîne de Markov [65]	42
1.37 Gestion énergétique de Lin et al. [65]	44
1.38 Gestion énergétique de Sun et al. [113]	45
1.39 Excès de consommation par rapport au contrôleur idéal [54]	45
1.40 Gestion énergétique de Johannesson et al. [54]	45
1.41 Impact du facteur d'équivalence sur le niveau de SOC final pour un type de cycle différent et pour une distance différente [83]	47
1.42 Principe de la stratégie en temps réel [13]	48
1.43 Gestion énergétique de Bernard et al. [13]	49
1.44 Gestion énergétique de Vajedi et al. [125]	49
1.45 Cycles représentatifs et principe de la stratégie mise en place [64]	50
1.46 Gestion énergétique de Li et al. [64]	50
1.47 Gestion énergétique de Back et al. [9]	52
1.48 Intégration du contrôle prédictif dans l'environnement du véhicule [34]	53
1.49 Gestion énergétique de Debert et al. [34]	53
1.50 Neurone artificiel[128]	54
1.51 Représentation simplifiée d'un réseau de neurones artificiels [128]	54
1.52 Gestion énergétique envisagée pour la suite du mémoire	56
2.1 Motivation des déplacements [53]	58
2.2 Répartition de la population suivant la méthode des quotas	58
2.3 Photo du premier boîtier prototype réalisé	59
2.4 Transformée de Fourier des signaux acquis à différentes fréquences	61

2.5	Influence de la fréquence d'acquisition	62
2.6	Représentation du temps passé par intervalle d'accélération (intervalle par pas de 0.01ms^2)	63
2.7	Reproductibilité des résultats de l'accéléromètre suivant l'axe longitudinal	64
2.8	Principe de fonctionnement d'un GPS de type RTK	65
2.9	Comparaison des coordonnées GPS entre le système d'acquisition et le module RTK	66
2.10	Validation des mesures de coordonnées GPS	66
2.11	Comparaison des profils de vitesse issus du GPS entre le système d'acquisition et le module RTK	67
2.12	Répartition de l'écart de vitesse entre le boîtier B11 et le GPS RTK	69
2.13	Reproductibilité des relevés de vitesse issus du GPS	69
2.14	Dispersion des mesures de vitesse autour de la moyenne	70
2.15	Exemple d'inter-corrélation (issu de [122])	71
2.16	Répartition de la distance journalière parcourue par les automobilistes de l'étude	73
2.17	Déroulement de la procédure de calcul de prédictibilité	73
2.18	Répétition des trajets	74
2.19	Totalité des trajets pour les automobilistes ayant les prédictibilités extrêmes	75
2.20	Position des points de départ et des points d'arrivée de l'ensemble des trajets d'un automobiliste	76
2.21	Représentation de la moyenne	77
2.22	Exemple élémentaire de chaîne de Markov à 2 états	78
2.23	Matrice de transition d'une chaîne de Markov [110]	78
2.24	Exemple de trajet et de cartographie associée	78
2.25	Principe de l'algorithme d'un processus de Markov [110]	79
2.26	Comparaison de profil de vitesse entre profil généré, profil moyen et profil réel	80
3.1	NOAO	84
3.2	Présentation du modèle REM créé	88
3.3	Repère initial (A,B,C) du stator et repère (d,q) de Park (issus de [2])	90
3.4	Circuits électriques équivalents avec résistance de pertes fer en parallèle	91
3.5	Valeur de la résistance interne du pack batterie de la NOAO suivant le mode de fonctionnement et le SOC	92
3.6	Cartographie de rendement du moteur thermique	93
3.7	Cycle de validation du modèle	93

3.8	Comparaison entre vitesse expérimentale et numérique	94
3.9	Comparaison des résultats du moteur électrique entre expérimentaux et numériques	95
3.10	Comparaison des résultats de la génératrice entre expérimentaux et numériques	96
3.11	Comparaison des résultats de la batterie entre expérimentaux et numériques	97
3.12	Comparaison entre consommation de carburant expérimentale et numérique	98
3.13	Cartographie de rendement du moteur électrique	99
3.14	Cartographie de rendement de la génératrice	99
3.15	Respect de la consigne de vitesse sur les 3 cycles considérés pour les deux approches	101
3.16	Consommation pour les 2 approches sur le cycle rampe	102
3.17	Consommation pour les 2 approches sur un cycle réel	103
3.18	État de charge de la batterie pour les 2 approches sur le cycle rampe . . .	104
3.19	Etat de charge de la batterie pour les 2 approches sur le cycle WLTC . . .	105
3.20	État de charge de la batterie pour les 2 approches sur un cycle réel . . .	106
3.21	Schéma bloc de la stratégie de gestion énergétique créée	111
3.22	Comparaison entre cartographie initiale et points issus du modèle linéaire .	112
3.23	Validation de la linéarisation pour plusieurs cycles de référence	113
3.24	Profil considéré pour l'étude de l'impact de l'horizon de prédiction	114
3.25	Répartition de l'optimalité de la stratégie	115
3.26	Optimalité moyenne en fonction du nombre de changement de prédiction .	116
3.27	Impact de l'anticipation du ralentissement sur les différents paramètres à $SOC_{init} = 0.9$	117
3.28	Impact d'un ralentissement sur les différents paramètres à $SOC_{init} = 0.6$. .	118
3.29	Timing d'anticipation du ralentissement	119
3.30	Timing et impact de l'anticipation du ralentissement	120

LISTE DES TABLES

1	Norme Euro 6b concernant les véhicules Diesel (mg/km)	1
1.1	Comparaison des différentes architectures	10
1.2	Paramètres influant la consommation de carburant et les émissions de polluants [38]	14
1.3	Ordre de l'impact des paramètres influents [14]	15
1.4	Présentation des paramètres de l'étude [14]	16
1.5	Comparaison des paramètres pour les différentes méthodes d'analyse [14]	17
1.6	Données permettant de caractériser une route [95]	20
1.7	Trajets et besoin en énergie [91]	22
1.8	Comparaison de l'autonomie [km/l] avec la RB par rapport au PMP, au CD/CS et au véhicule conventionnel en pourcentage [123]	31
1.9	Résultats de la simulation (fuel + 40.NO _x + 800.PM [g/mile]) [66]	32
1.10	Exemple de règles de logique floue	34
1.11	Résultats des trois types de contrôleurs sur le LA92 et sur un cycle mixte [94]	35
1.12	Système d'inférence du contrôleur de logique floue [80]	36
1.13	Résultats et comparaison entre règle optimale et basculement de règles [80]	37
1.14	Résultats et comparaison entre IDP et basculement de règles [80]	37
1.15	Comparaison des résultats entre la SDP et la méthode de règles déterministes (fuel + 40.NO _x + 800.PM [g/mile]) [65]	43
1.16	Résultats de la consommation de carburant, en Miles Per Gallon (MPG), pour chaque stratégies de Vajedi [125]	48
1.17	Supplément de CO ₂ pour différents cycles et une stratégie de maintien de charge à 30% [34]	53
1.18	Avantages et inconvénients des familles de stratégies	55
2.1	Déplacements quotidiens des français	67
2.2	Tableau comparatif des solutions existantes dans le commerce par rapport au moyen d'essai mis en place	68
2.3	Détails de la trame GPS	68
2.4	Coefficient de corrélation avec l'histogramme des données à 500 Hz	68

2.5	Coefficient de corrélation R des histogrammes à 100 Hz moyennés sur 10 Hz	68
2.6	Ecart relatif de positionnement entre les boîtiers d'acquisition et le GPS de type RTK	69
2.7	Ecart relatif de vitesse entre les boîtiers d'acquisition et le GPS de type RTK	69
2.8	Ecart relatif d'énergie entre les boîtiers d'acquisition et le GPS de type RTK	69
2.9	Comparaison entre les résultats de l'étude expérimentale et l'étude du Ministère du Développement Durable (données journalières)	72
2.10	Energie nécessaire et énergie récupérable	72
2.11	Variabilité des coordonnées de départ et d'arrivée pour un même trajet . .	75
2.12	Exemple d'inter-corrélation normalisée sur 3 cycles de vitesse représentant le même trajet	81
2.13	Exemple de calcul de probabilité	81
3.1	Paramètres de la Noao	85
3.2	Récapitulatif des éléments constitutifs du formalisme REM 1/2	86
3.3	Récapitulatif des éléments constitutifs du formalisme REM 2/2	87
3.4	Ecart relatif de résultat entre modèle quasi-statique et REM	100
3.5	Résultats comparatif de l'application de la DP du cycle le plus représentatif sur les autres cycles d'un même trajet	109
3.6	Optimalité de la stratégie en fonction de l'horizon de prédiction choisi	114

INTRODUCTION GÉNÉRALE

Le réchauffement climatique, phénomène avéré dont la cause principale est l'augmentation constante de la concentration de CO₂ dans l'atmosphère, est au centre des préoccupations. Les transports sont responsables de près d'un quart des émissions de CO₂ (23%) [50]. Ils sont donc parmi les principaux affectés par cette transition écologique, puisque l'IEA (International Energy Agency) prévoit une augmentation importante des ventes de véhicules dans les prochaines années. Ce travail vise à répondre à cette problématique et adapter la gestion énergétique du véhicule au trajet et au comportement du conducteur

Pour réduire les émissions néfastes, l'Union Européenne a mis en place dès 1992 une norme, appelée norme Euro. Il s'agit de règlements qui fixent les limites maximales de rejets polluants pour les véhicules roulants. La norme actuellement en vigueur est la norme Euro 6c qui préconise les valeurs présentées dans le tableau (table 1). La norme Euro 6c est identique en chiffre à la norme euro 6b (mise en application dès septembre 2014) mais le cycle d'homologation est désormais le WLTC (Worldwide harmonized Light vehicles Test Cycles). L'entrée en vigueur de cette dernière menace les moteurs diesel étant donnée les limites fixées pour les émissions de NO_x et de particules, et certains constructeurs comme PSA ont annoncé la fin des développements sur ce type de moteur.

TABLE 1 – Norme Euro 6b concernant les véhicules Diesel (mg/km)

Norme	Euro 1	Euro 2	Euro 3	Euro 4	Euro 5	Euro 6b
Oxydes d'azotes (NO _x)	-	-	500	250	180	80
Monoxyde de carbone (CO)	2720	1000	640	500	500	500
HC + NO _x	970	900	560	300	230	170
Particules (PM)	140	100	50	25	5	4,5
Particules (PN) (Nb/km)	-	-	-	-	6.10 ¹¹	6.10 ¹¹

De plus, le 8 novembre 2017, la Commission Européenne a présenté une proposition législative concernant les émissions de CO₂ pour les véhicules légers dans l'Union Européenne à partir de 2020 [120]. Cette limite exprimée en g/km est directement liée à la consommation du véhicule. Par conséquent, les travaux de thèse s'inscrivent directement dans le cadre de cette législation.

En parallèle, l'accord de Paris sur le climat marque un nouveau tournant important dans la lutte contre le réchauffement climatique. En effet, ce texte signé par 174 pays et l'Union Européenne, prévoit de contenir d'ici à 2100 le réchauffement climatique « bien en dessous de 2 °C par rapport aux niveaux préindustriels » et si possible de viser à « poursuivre les efforts pour limiter la hausse des températures à 1,5 °C » [124]. Ce dernier point a été ajouté sous la pression des 44 états insulaires les plus exposés au réchauffement climatique alors qu'ils ne sont responsables que de 0.00001% des émissions globales. Ce texte a été ratifié par au moins 55 parties responsables de 55% des émissions dès le 4 octobre 2016 rendant son entrée en vigueur effective 30 jours plus tard.




FIGURE 1 – Objectif d'électrification du parc automobile suivant différents scénarios

Dans son dernier rapport annuel, l'IEA a présenté des mesures afin de respecter cet engagement, notamment dans le domaine des transports (figure 1). Ainsi, la vente de véhicules hybrides doit être multipliée par cent d'ici 2030. Les scénarios 2DS et B2DS présentés permettraient d'avoir 50% de chance de maintenir le réchauffement climatique respectivement à 2°C et 1.75°C. Pour cela, les émissions de CO₂ cumulées entre 2015 et 2100 doivent être limitées respectivement à 1100 GtCO₂ et 750 GtCO₂ (figure 2). En excluant la possibilité d'avoir un bilan d'émission négatif, il est impératif que les émissions de CO₂ deviennent nulles au cours de la seconde moitié du siècle (à partir de 2090 pour le 2DS et à partir de 2060 pour le B2DS), afin d'atteindre les objectifs de l'accord de Paris. Concernant la vente de véhicule électrique, le scénario 2DS prévoit un parc automobile constitué de 10% de véhicule électrique en 2030 et 60% en 2060. Quant au domaine des 2 roues le parc sera entièrement électrique en 2055. Dans le B2DS, cette date est avancée à 2045 et 85% du parc automobile est électrique en 2060.

Il existe de nombreuses solutions pour abaisser le taux d'émission, tant sur le plan social que technique, et celles-ci devront être menées de pair. Les leviers sociaux consistent à remplacer la voiture thermique dans les solutions de mobilité. En effet, inciter la population à se déplacer en transport en commun ou même par des moyens complètement propres tels que le vélo ou la marche, sera nécessaire. Toutefois, ce changement de mentalité ne sera pas immédiat et encore moins total. C'est pourquoi, les recherches afin d'améliorer l'efficacité des moyens de transport sont primordiales. Concernant l'automobile, il existe de nombreuses pistes afin d'abaisser la consommation de carburant et les émissions : allègement du véhicule, amélioration de la combustion moteur, réduction des pertes sur chaque organe, etc... Toutefois, la principale, dont les gains sont les plus importants et ce de manière immédiate reste l'électrification des véhicules ou tout du moins l'hybridation dans un avenir plus proche.

Selon le CCFA (Comité des Constructeurs Français de l'Automobile), l'électrique représente 1.18% des ventes de véhicules neufs en 2017, et l'hybride 3.8% ce qui reste fortement minoritaire [22]. Nonobstant, de nombreux constructeurs travaillent actuellement sur l'électrification de leurs véhicules et plusieurs ont déjà annoncé leurs objectifs de vente de véhicules électriques et hybrides durant les prochaines années. Les plus ambitieux sont Jaguar Land Rover qui ont annoncé vouloir abandonner le véhicule thermique pur dès 2020, alors que Porsche a annoncé que 50% de ces véhicules seraient électriques en 2023. General Motors, Toyota et Volvo ont déclaré vouloir vendre 1 million de véhicules électriques en 2025, quand Aston Martin annonce qu'en 2030, 25% de ses ventes sera un véhicule électrifié (électrique ou hybride). Enfin, BMW proposera 25 véhicules

électrifiés dont 12 entièrement électriques en 2025, alors que l'alliance Renault Nissan & Mitsubishi souhaite offrir 12 nouveaux véhicules électriques dès 2022.

Au-delà des constructeurs, les gouvernements ont un rôle majeur à jouer dans cette transition et tous n'ont pas les mêmes ambitions. Les pays les plus ambitieux sont l'Inde et la Norvège. Le premier a annoncé vouloir 6 millions de véhicules électriques en circulation en 2020 et souhaite définitivement arrêter la vente de véhicule essence et diesel à partir de 2030. Cette restriction permettrait de réduire de 37% les émissions de CO₂ du pays. Il reste toutefois très voire trop ambitieux compte tenu des chiffres de 2016 (seulement 5000 voitures électriques sur 6 millions) [101]. La Norvège, quant à elle, est l'élève modèle avec 29% de ventes de véhicules neufs hybride ou électrique en 2016 (16% si l'on s'en tient aux véhicules électriques) [119]. En 2017, ces chiffres ont grimpé à 50% dont 20% d'électriques. Le pays envisage donc des ventes 100% électriques dès 2025. Ces résultats ont été atteints sans avoir légiféré d'interdiction de véhicules thermiques, mais en proposant des avantages pécuniaires (exemption de TVA à l'achat,...) et non pécuniaires (places de parking et électricité gratuites). En milieu de classe se positionne la France et le Royaume-Uni qui ont fait sensiblement les mêmes déclarations : la fin de la vente de voiture thermique d'ici 2040. Deux grandes nations automobiles manquent à l'appel concernant les prises de décision. Il s'agit des Etats-Unis et de l'Allemagne qui ne tiendront pas leur engagement d'un million de véhicules électrique en circulation en 2020, et qui n'ont pas pris de nouvelles mesures pour y parvenir. Notons cependant qu'en Allemagne certaines villes ont restreints la circulation de véhicules polluants comme Stuttgart ou Hambourg et prochainement Munich et Düsseldorf. Et enfin la Chine qui reste le leader mondiale avec 25 millions de véhicules vendus en 2016, a pris une mesure en deux temps : dès 2019 tous les constructeurs devront vendre 10% de voitures électriques ou hybrides, et ce chiffre grimpera à 12% dès 2020.

Bien que toutes ces annonces soient prometteuses, il existe quelques freins à ce déploiement. Le premier est psychologique et porte le nom de « Range Anxiety »¹. En effet de nombreuses personnes ont peur de ne plus être libre de leurs déplacements à cause de l'autonomie actuelle des véhicules électriques. D'autres freins sont d'ordre technique. Il s'agit de l'implantation des bornes de recharges, de la production d'électricité supplémentaire et de l'aménagement des réseaux électriques afin de répondre à la demande à chaque instant [3]. Pour ces différentes raisons, les véhicules hybrides semblent être la

1. Désigne l'appréhension que le véhicule n'ai pas l'autonomie nécessaire pour arriver à destination.




FIGURE 2 – Objectif d'émissions de CO₂ annuelles (à gauche) et cumulées (à droite) pour le siècle actuel

solution à court et moyen terme, c'est pourquoi ces travaux ont été réalisés.

En 2015, les stratégies de gestion énergétique des véhicules hybrides, et notamment des range extenders dans des véhicules électriques, étaient basées sur de simples règles principalement liées à la vitesse et l'état de charge de la batterie. Ceci n'est pas optimal et un exemple résume les difficultés : une personne habitant au bord d'une route limitée à 80, sort de chez elle avec la batterie de son véhicule entièrement chargée. Elle atteint rapidement la limite maximale à laquelle la voiture est propulsée thermiquement. Son parcours se résumant à une route limitée à 80km/h, elle arrivera à destination avec la batterie pleine alors que l'utilisation de la batterie aurait pu permettre une réduction de consommation et d'émission. Une analyse du parcours aurait permis de vider les batteries au cours du trajet.

Danielson Engineering est une société d'engineering, labellisée SRC (Société de Recherche sous Contrat) spécialisée dans la conception, la fabrication et le développement de moteurs prototypes destinés à valider de nouveaux concepts de motorisation pour les constructeurs automobiles et équipementiers. Ces travaux de recherche trouvent leur place dans le cadre du développement en interne d'un moteur thermique à vocation Range-Extender, et dans un contexte plus global de travail avec Everest Team. Ce dernier est un groupement d'intérêt économique auquel fait partie Danielson Engineering. Initialement, la thèse s'inscrivait dans le cadre du projet EVEREX consistant à développer, produire et vendre un véhicule hybride de type Range-Extender.

La thèse se décompose en trois parties. Le chapitre 1 définit le terme d'hybride, puis classifie les différentes architectures possibles en dressant les avantages et inconvénients de chacune. Les outils de modélisation sont présentés et enfin, les différentes stratégies de contrôle sont décrites. Le chapitre 2 s'intéresse à la mobilité et dégage, à partir des informations relevées lors d'une campagne d'essais, une méthode de prédiction de cycle. Le chapitre 3 présente la modélisation du véhicule ainsi que sa validation. La méthode d'optimisation utilisée est détaillée, et les résultats obtenus sur des cycles réels sont présentés. Le travail s'achève avec les conclusions et perspective.

DÉFINITIONS ET STRATÉGIES DE CONTRÔLE APPLIQUÉES AUX VÉHICULES HYBRIDES

Le terme hybride, lorsqu'il concerne le domaine automobile, désigne dans l'opinion publique un véhicule dont la propulsion est assurée par un Moteur à Combustion Interne (MCI) et un moteur électrique. Cette vision est réductrice et nous consacrerons donc la première partie à la définition et la caractérisation des véhicules hybrides. La seconde partie présentera les différentes méthodes utilisées pour la modélisation du véhicule. Enfin, la dernière partie s'attachera à présenter les stratégies de contrôle des groupes motopropulseurs (GMPs) hybrides.

1.1/ ASPECTS TECHNOLOGIQUES

1.1.1/ TYPE D'HYBRIDATION

Les termes hybrides et électriques sont couramment utilisés en automobile. Pour autant, ils sont génériques et ne permettent pas de distinguer avec précision les différents types, architectures et stratégies d'hybridation. Les plus courantes sont référencées sur la figure 1.1. Une analyse comparative des différents types d'hybridation a été faite par G. Offer et al. [82] ou encore J. Van Mierlo et al. [126]. De plus, A. Da Costa et al. [33] ont étudié les possibilités de gain de consommation en fonction de l'architecture véhicule.

Hybride faible

Les Hybrides faibles, aussi appelé "mild hybrid", sont équipés d'un moteur électrique qui n'assure jamais seul la propulsion. Son rôle se limite à apporter un couple supplémentaire au démarrage et lors de fortes accélérations. Lors de la phase de décélération et de freinage, le moteur électrique agit comme générateur et recharge la batterie de très faible capacité. Ces véhicules s'opposent aux véhicules dit "full hybrid", qui regroupent les trois types d'hybrides présentés par la suite. La Honda Insight fait partie de cette catégorie.




FIGURE 1.1 – Différent types d'hybrides en fonction du niveau d'électrification

Hybrid Electric Vehicle (HEV)

Le Technical Committee 69 (electric road vehicles) définit un véhicule électrique hybride comme un véhicule dont la propulsion peut être assurée par au moins deux sources ou convertisseurs d'énergie dont l'un d'eux est électrique. Il existe alors de nombreuses possibilités d'hybridation telles que batterie/MCI, batterie/super capacité, batterie/solaire ou encore batterie/volant d'inertie... [23]. Dans ce document, le terme HEV sera utilisé pour désigner un véhicule équipé d'une batterie et d'un MCI. La Toyota Prius dans sa version de base, commercialisée pour la première fois en 1997, est un HEV.

Plug-in Hybrid Electric Vehicle (PHEV)

Un hybride plug-in est un véhicule hybride dont le composant de stockage peut être rechargé par une source externe d'électricité. L'avantage de ce type de véhicule est qu'il peut fonctionner sans essence au quotidien [74].

Les marques allemandes comme Volkswagen avec sa Golf GTE, Audi avec la A3 Sportback e-tron ou encore Porsche avec la 918 Spyder, ont adopté ce type d'hybridation. Le groupe Volkswagen annonçait début 2015 qu'une dizaine de ses véhicules seraient convertis à l'hybride rechargeable. La Toyota Prius a été commercialisée dans sa version plug-in pour la première fois en 2012. Depuis 2016, la seconde génération est commercialisée ce qui montre l'engouement de Toyota pour cette technologie.

Electric Vehicle with Range Extender (EVRE)

Ce concept est apparu pour répondre aux limitations d'autonomie des véhicules électriques [89] et ainsi faire face au "Range anxiety". Un véhicule électrique avec un prolongateur d'autonomie est un hybride série dont la principale source d'énergie est la batterie. Le moteur à combustion interne sert quant à lui à recharger la batterie [89]. Sa puissance est donc limitée. La différence avec un véhicule hybride faible se situe donc dans la source primaire d'énergie et par conséquent dans le dimensionnement des composants.

La Chevrolet Volt et la Opel Ampera sont deux véhicules de ce type. La BMW i3 est un véhicule électrique (BEV) mais le constructeur propose en option un MCI pour améliorer son autonomie.

Battery Electric Vehicle (BEV)

Un véhicule électrique est un véhicule dont la propulsion est assurée par une ou plusieurs sources d'énergie de nature purement électrique. Ces dernières peuvent être un panneau solaire, une batterie, une pile à combustible (Fuel Cell (FC)), une super-capacité (SC) [60, 96]. Dans le cas d'un BEV, la source est obligatoirement une batterie. Durant leur utilisation, les véhicules électriques ont un bilan nul en termes d'émissions polluantes. Ceci les rend intéressants d'un point de vue environnemental et leur permettra de rouler dans les nouvelles "zones zéros émissions"¹.

La Zoé de Renault, la Leaf de Nissan et la Bluecar de Bolloré sont les principales voitures électriques vendues en France.

1.1.2/ ARCHITECTURE

Pour chaque type d'hybridation vu précédemment, il existe différents types d'architectures permettant de relier les deux modes de propulsion : série, parallèle, combinée et une multitude d'autres groupée sous le nom complexe [69]. Elles sont toutes présentées sur la figure 1.2. Les avantages et inconvénients de chaque architecture sont résumés dans le table 1.1. La table s'appuie à la fois sur l'analyse établie dans les paragraphes suivants et sur le travail de M. Zhang [136].

a) Série

Le véhicule est composé d'un moteur électrique, d'un groupe électrogène (moteur thermique et générateur) et d'une batterie (figure 1.2.a). L'architecture série a pour principale caractéristique le découplage du moteur thermique des roues [21, 93, 104]. La propulsion est alors assurée par le moteur électrique qui reçoit de l'énergie soit du groupe électrogène, soit de la batterie, soit des deux. La propulsion est donc purement électrique [93]. L'architecture série possède deux avantages. D'une part, le moteur thermique peut opérer sur son meilleur point de rendement puisqu'il est mécaniquement déconnecté de la roue [24, 74, 103]. D'autre part, elle n'a besoin que d'une seule transmission mécanique. Cependant, lorsque le moteur thermique est sollicité pour la propulsion, l'énergie nécessaire transite par le moteur thermique, le générateur et le moteur électrique, ce qui induit une cascade de rendement [74, 93].

A faible vitesse, l'utilisation d'un moteur électrique permet de gagner en agrément de conduite. C'est pourquoi cette architecture est utilisée dans les véhicules de transport en commun, qui parcourent des cycles composés de nombreux arrêts et redémarrage. Daimler Chrysler a, par exemple, équipé un bus Orion 7 d'une combinaison moteur diesel/moteur électrique avec une architecture série. Celui-ci est utilisé depuis 2005 dans les rues de New York. Du côté automobile, l'architecture série est adoptée par la Chevrolet Volt.

b) Parallèle

Dans un véhicule hybride parallèle, les deux unités de puissance sont directement connectées à la transmission mécanique (figure 1.2.b). Il peut fonctionner en tout électrique, en thermique ou en utilisant les deux [24, 105]. Contrairement à la première, cette architecture nécessite deux transmissions mécaniques.

1. Zones dans lesquelles seuls les véhicules n'émettant pas d'émissions polluantes sont admis.




FIGURE 1.2 – Classification des différentes architectures

Dans cette configuration, le moteur électrique peut servir de générateur et recharger les batteries. La recharge peut se faire pendant la récupération d'énergie au freinage ou grâce au moteur thermique [24, 93]. Honda utilise cette technologie sur la Insight hybrid.

c) Combinée ou série-parallèle

Cette architecture combine les deux architectures précédentes et en possède les avantages (figure 1.2.c). Elle offre un plus grand degrés de liberté pour sélectionner une répartition de puissance entre MCI et moteur électrique. Elle est donc avantageée quelque soit la situation. Cependant, pour ce type d'architecture, il faut réaliser une transmission spécifique. Elle est donc plus compliquée mécaniquement et ceci affecte directement son




FIGURE 1.3 – Architecture de la Toyota Prius (tirée de les-moteurs-tpe.e-monsite.com)

coût [24].

Cette architecture a connu un engouement grâce à Toyota qui a équipé la Prius du Toyota Hybrid System (THS) sur les modèles de 1997 à 2003 puis du THS-II au delà. Le système est présenté sur la figure 1.3. Par la suite, le système a été amélioré, devenant le Hybrid Synergie Drive (HSD), en vue d'une utilisation hors marque. Toyota a vendu une licence d'exploitation à Nissan pour son Altima Hybrid. Cette technologie équipe aussi les Toyota Auris et Yaris HSD et le SUV Lexus RX150h.

d) Complexe

L'architecture complexe consiste, à partir d'un véhicule conventionnel à deux roues motrices, à associer un ou deux moteurs électriques sur l'autre train roulant.

De nombreux constructeurs ont opté pour cette solution. Toutefois deux styles s'opposent. Certains choisissent d'avoir un essieu électrique et un essieu thermique (figure 1.2.d), d'autres un essieu électrique et un essieu hybride (figure 1.2.e). Le groupe PSA a adopté la première stratégie et les véhicules DS5 HYbrid4, 3008 HYbrid4 et 508 RXH HYbrid4 sont des hybrides diesel/batterie. On trouve parfois ce style d'architecture complexe sous l'appellation "parallèle liée par la route". La vue en transparence de la DS5 HYbrid4 est présentée sur la figure 1.4. BMW ont adopté la deuxième solution sur leur modèle i8, tout comme Porsche avec la 918 Spyder.

1.1.3/ RÉPARTITION DE PUISSANCE ET AUTONOMIE ÉLECTRIQUE

Comme vu précédemment, il existe différents types d'hybride et différentes architectures. L'objectif de cette partie est d'observer si une tendance existe concernant la répartition de puissance entre thermique et électrique dans la gamme de véhicule hybride disponible à ce jour. De même, l'autonomie électrique en fonction du type d'architecture utilisé est étudié. Pour cela, le marché automobile actuel est présenté de manière non exhaustive (figure 1.5 et figure 1.6).

La figure 1.5 présente le niveau d'électrification (Puissance électrique/Puissance totale) des véhicules considérés. Les BEV ont un rapport de 1 car elles sont purement électrique. Les EVRE ont un ratio supérieur à 0,5 car la source principale de propulsion de ce type d'hybride est le moteur électrique (figure 1.1). Le MCI est dimensionné uniquement de

CITROËN DS5 HYbrid4


FIGURE 1.4 – Architecture de la DS5 Hybrid4 (tirée de www.moteurnature.com)

TABLE 1.1 – Comparaison des différentes architectures

Architecture	Avantages	Inconvénients
Série	- une seule transmission mécanique - moteur thermique à son rendement optimal - efficace sur cycle urbain - Agrément de conduite à faible vitesse	- cascade de rendement - économies moindre à grandes vitesses
Parallèle	- moteur thermique sur son point de fonctionnement optimal à haute vitesse - absence de générateur	- perte par friction en phase de récupération d'énergie - vitesse de rotation des moteurs imposées par le véhicule - deux transmissions mécaniques nécessaires
Combinée	- dispose des avantages de série et de parallèle - point optimal pour chaque situation	- nécessite une transmission spécifique - coût
Complexe	- passage en quatre roue motrice - stratégie de répartition de puissance	- poids - coût

manière à prolonger l'autonomie du véhicule, d'où sa faible puissance. Par contre, aucune tendance n'est actuellement observée sur le marché automobile concernant la différence sur la répartition de puissance entre les HEV et les PHEV.

La figure 1.6 représente les mêmes données, cette fois coloriées par rapport à l'architecture du véhicule. Les conclusions que l'on peut tirer sont les mêmes que précédemment puisque les raisons viennent plutôt du type d'hybridation que de l'architecture. C'est pourquoi l'architecture série (qui n'est utilisée que pour faire des range extender en au-




FIGURE 1.5 – Analyse du niveau d'électrification par type d'hybridation

tomobile) a un niveau supérieur à 0,5 i.e. une source d'énergie principale électrique. On ne peut donc pas conclure qu'une architecture est plus utilisée pour un certain segment ou pour un certain rapport de puissance.

Globalement on remarque que plus l'on tend vers des grands segments, plus le niveau d'électrification est faible. Mais il n'est pas possible de tirer d'autres conclusions concernant l'impact de l'architecture ou du type d'hybridation. Il aurait été intéressant de connaître la stratégie utilisée pour chaque véhicule afin de savoir s'il existe une corrélation entre celle-ci et l'architecture ou le type d'hybridation, mais ces données ne sont pas dévoilées par les constructeurs.

1.2/ GESTION ÉNERGÉTIQUE DU VÉHICULE

1.2.1/ DÉFINITIONS

La gestion énergétique du véhicule désigne la méthode mise en place pour assurer la propulsion du véhicule. Elle concerne donc la stratégie qui en sera l'élément clé, mais tient aussi compte du modèle du véhicule ou de la prise en compte du conducteur. Elle va agir sur la répartition de puissance entre les différents modes de propulsion pour minimiser le plus souvent le coût énergétique global du trajet.

Pour comparer les différentes méthodes de gestion énergétique de la littérature, un schéma de principe décomposé en 10 sections a été mis en place (figure 1.7). Dans la suite du chapitre, il sera utilisé et complété pour chaque article détaillé afin de faciliter la comparaison entre les différentes études.

Au centre du schéma de principe, la stratégie employée sera précisée. Elle aura pour objectif de délivrer une consigne qui sera appliquée pour assurer la propulsion, à partir de




FIGURE 1.6 – Analyse du niveau d'électrification suivant l'architecture du véhicule

paramètres d'entrée. Cette stratégie pourra reposer sur un modèle de véhicule, la génération d'un cycle et/ou d'un profil conducteur. Le modèle du véhicule dépend directement du type d'hybridation, de son architecture et éventuellement du segment automobile. Les informations sur le cycle permettront sa génération, et seront parfois utilisées pour établir un profil conducteur associé. La stratégie a pu être construite ou optimisée de manière préalable hors ligne². Cette possibilité est représentée par la section "construction préalable". La flèche qui part de celle-ci est dessinée en pointillés puisque la construction est effectuée hors ligne. Et enfin pour avoir une comparaison, un critère d'évaluation est nécessaire. Dans la suite, lorsqu'une section est grisée, cela signifie que la partie qu'elle concerne n'est pas étudiée ou renseignée par les auteurs de l'étude.

1.2.2/ CONDUCTEUR

Intuitivement, on peut penser que les habitudes de conduites du conducteur (anticipation au freinage, type de relance...) vont avoir un impact direct sur la consommation et les émissions polluantes du véhicule. Dès 1988, J. Hooker [49] liste un certain nombre de recommandations pour abaisser la consommation des véhicules conventionnels. De plus, cette intuition est renforcée par la notion d'éco-conduite apparue depuis quelques années et dont plusieurs auteurs étudient l'influence sur les émissions et la consommation du véhicule [70, 71, 100, 111, 10, 12]. Le principe d'éco-conduite repose sur quelques recommandations de base telles que [133] :

- Anticiper le trafic pour adopter une vitesse constante et éviter les freinages brusques et les arrêts
- Accélérer de manière lisse pour atteindre la vitesse souhaitée en utilisant le plus haut rapport possible

2. en dehors de la phase d'utilisation.




FIGURE 1.7 – Gestion énergétique du véhicule

- Changer de rapport dès que possible (entre 1500 et 2500 tr/min)
- Respecter les limitations de vitesse
- Utiliser le frein moteur lorsque cela est possible

On parle couramment de conduite souple ou agressive mais il est difficile de caractériser ces types de conduites en terme de données. Pour cela, il est nécessaire de savoir quels paramètres vont les différencier. Dès lors il reste à savoir qu'elles sont les délimitations de chaque type de conduite.

E. Ericsson [38] a déterminé par une étude expérimentale quels paramètres ont un impact sur la consommation et les émissions. Pour cela, elle a collecté des données issues de 2 550 trajets représentant un total de 18 945 km. Cinq véhicules de segment différent ont été prêtés à 30 familles pendant 2 semaines. Au final 45 conducteurs différents ont utilisé les véhicules.

Au départ 62 paramètres ont été considérés puis ils ont été ramenés à 16 paramètres indépendants par une analyse factorielle³ (à comprendre au sens anglo-saxon "factor analysis"). L'influence de ceux-ci a alors été étudiée en utilisant deux modèles d'émissions, un pour chaque voiture considérée dans cette partie. La simulation démontre que seulement 9 paramètres ont un impact significatif sur la consommation et les émissions (tableau 1.2). Ces paramètres peuvent être regroupés en 3 catégories dont l'ordre de l'impact a été repris par Birrell et al. [14] comme le montre la table 1.3.

Birrell et al. [14] ont utilisés plusieurs techniques pour déterminer quels paramètres ont le plus d'influence. Les paramètres étudiés sont au nombre de 12 et peuvent être regroupés en 4 catégories qui sont : l'accélération, la vitesse du moteur, la vitesse du véhicule et la position de la pédale d'accélération (tableau 1.5). Les 5 techniques utilisées pour étudier l'impact des paramètres sont :

- La connaissance des experts : les résultats sont déduits de l'analyse de graphes (tracés de données brutes et de données normalisées)
- Une régression linéaire multiple (MLR)

3. Méthode statistique permettant de réduire le nombre de variable en déterminant des variables non observées comme étant une combinaison des variables observées.

TABLE 1.2 – Paramètres influant la consommation de carburant et les émissions de polluants [38]

Driving pattern factor	Fuel	CO ₂	HC	NO _x
Deceleration factor	-	-		
Acceleration with strong power demand	++++	++++	+++	++++
Stop factor	+++++	+++++		
Speed oscillation factor	++	++		
Acceleration with moderate power demand	++	++		
Extreme acceleration	++	++	+++++	++++
Speed 15-30				-
Speed 90-110				
Speed 70-90	-	-		
Speed 50-70	-	-		
Late gear changing from gear 2 and 3	+	+	(++)	+++
Engine speed > 3500			(++)	++
Speed > 110				
Moderate engine speeds at gear 2 and 3	-	-		-
Low engine speed at gear 4	-	-		(-)
Low engine speed at gear 5	-	-		(-)

- Une régression linéaire générale (GLR)
- Des réseaux de neurones (NN)
- Un arbre de type CHAID (Chi-squared Automatic Interaction Detector)

Les données analysées proviennent de trois test effectués dans différentes villes (Warwickshire au Royaume-Uni pour WMG et Daegu en Corée du Sud pour DGIST). De même plusieurs scénarios, véhicules et catégories de conducteurs ont été considérés (tableau 1.4). Les résultats des analyses sont présentés dans la table 1.5. On constate que l'oscillation de la vitesse est le paramètre qui a le plus d'impact car quelle que soit la méthode, il apparaît comme important.

Plus récemment, plusieurs auteurs ont démontré quantitativement l'impact de certains facteurs cités précédemment. Par exemple, El-Shawarby et al. [36] ont démontré que les accélérations agressives augmentent la consommation et les émissions polluantes sur le cycle. Pour cela, il simule trois niveaux d'accélération : doux, normal et agressif (figure 1.8) qui représentent respectivement 40, 60 et 100% de l'accélération maximale du véhicule. La simulation est effectuée sur 1.4km ce qui est une distance supérieure à la distance nécessaire pour atteindre la vitesse maximale. Les résultats indiquent que les émissions de HC et de CO dépendent énormément de l'accélération avec une différence respective de 629% et 2015%. De plus la consommation augmente d'environ 70%. Cette étude permet de quantifier l'impact de l'accélération sur la consommation et les émissions polluantes.

D. Chrenko [30] a étudié l'influence de l'éco-conduite pour différentes architectures d'automobile : véhicule conventionnel, véhicule avec système stop and start, hybride série et hybride parallèle. Les paramètres de l'étude caractérisant l'éco-conduite sont l'accélération, la décélération et le rapport de vitesse maximale qui indique si le conducteur respecte la limitation de vitesse. L'auteur démontre qu'une relation linéaire existe entre le facteur de vitesse maximale et la consommation, ainsi qu'entre l'accélération et la

TABLE 1.3 – Ordre de l'impact des paramètres influents [14]

Category	Factor	Estimated order effect
Acceleration	Acceleration with strong power demand	1
	Extreme acceleration	2
	Acceleration with moderate power demand	6
Engine speed	Late gear changing from 2nd and 3rd	4
	Engine speed >3500 rpm	6
	Moderate engine speeds in 2nd and 3rd	5
Vehicle speed	Speed oscillation	6
	Stop factor	3
	Speed 50-70 km/h	6




FIGURE 1.8 – Etude du cumul de consommation et d'émissions polluantes sur une distance donnée pour différentes accélérations [36]

consommation pour les véhicules hybrides. Enfin, la décélération a un impact moindre sur la consommation.

Plusieurs études traitent de l'impact des paramètres tels que la vitesse ou l'accélération, mais très peu définissent les types de conduites en terme de grandeur. Dans l'optique de la mise en place d'une stratégie avec reconnaissance de type de conduite, il sera nécessaire d'obtenir une base de données qui permettra de les caractériser. Cela fera

TABLE 1.4 – Présentation des paramètres de l'étude [14]

		WMG	MIRA	DGIST
Scenario	Length (miles)	27.3	28.3	13.0
	Avg Time (mins)	65.8	50.1	31.7
	>60mph	17.9%	40.6%	45.7%
	>30mph <60mph	47.0%	50.3%	54.3%
	<30mph	35.1%	9.2%	0.0%
Vehicle	Make	Land Rover	Ford	Hyundai
	Model	Freelander	Focus	Genesis
	Fuel size	Diesel	Diesel	Petrol
	Engine Size	2.2	1.6	3.3
	Transmission	Manual	Manual	Auto
	Stop start	Y	N	N
Participants	Total	20	40	52
	Male/Female	14/6	30/10	26/26
	Average age	35.8	41.9	43.9

l'objet d'un chapitre dans la suite du travail proposé.

1.2.3/ CYCLES

On sous-entend par "cycle" ou plus précisément "cycle de conduite", la vitesse du véhicule en fonction du temps. Quelle que soit l'étude, un cycle de validation est utilisé pour évaluer la gestion énergétique mise en place. Plusieurs études ont montré que le cycle considéré lors de l'évaluation a un impact d'ordre 1 sur la consommation et les émissions polluantes ([72], [116]).

D'un point de vue réglementation, les essais de normalisation des véhicules se font sur des cycles standardisés. Ces cycles dépendent de la zone géographique dans laquelle le véhicule va être commercialisé. Les plus connus sont ceux de l'Europe (NEDC figure 1.9), des Etats-Unis (FTP-75 pour des conditions urbaines, HWFET pour des conditions autoroutières figure 1.10) et du Japon (JP10-15, JC08 figure 1.11). Le cycle NEDC n'étant pas représentatif de conditions réelles de circulation de part ses accélérations et décélérations purement linéaires, d'autres cycles standardisés pour l'Europe ont été conçus (figure 1.12). Il s'agit des cycles Artemis basés sur une étude statistique européenne dans le cadre du projet Artemis [6]. Il est composé de 3 configurations : urbain (a), extra-urbain (b) et autoroutier (c). Enfin, pour avoir une norme mondiale, le cycle WLTP a été mis en place et son utilisation était initié en 2017 [73]. Il est lui aussi constitué de trois classes qui dépendent de la puissance massique⁴.

Dans la littérature, les auteurs considèrent parfois des cycles réels issus de relevés dans certaines villes comme le TEH-CAR à Téhéran. Un cycle de montagne nommé VAIL2NREL a été utilisé par quelques auteurs [121, 123]. Ces cycles sont présentés sur la figure 1.13.

Il existent donc de nombreux cycles, standards ou spécifique⁵, mais aucun ne fait figure

4. Puissance du moteur / masse à vide en ordre de marche.

5. On désigne par cycle spécifique tout cycle qui n'est pas standards, qu'il soit issu de données expérimentales ou créé par un auteur.

TABLE 1.5 – Comparaison des paramètres pour les différentes méthodes d'analyse [14]

Category	Driving parameter	Expert	MLR	GLR	NN	CHAID
Acceleration (m/s ²)	Max acceleration	✓			2	
	Max deceleration		3	3		
	Max lateral accel (L)					
	Max lateral accel (R)					
Engine speed (rpm)	Ave engine speed		2	2		
	Max engine speed	✓				3
Vehicle speed (mph)	Ave speed					
	Max speed					
	SD of speed	✓	1	1	3	2
Throttle(%)	Ave throttle position	✓			1	1
	Max throttle position					
	SD of throttle position					

de référence mondiale dans la bibliographie. Le choix du cycle de validation est propre à chaque auteur.

Dans une majorité d'articles, le cycle de validation est renseigné directement. Cette connaissance du cycle est indispensable pour certaines stratégies de gestion énergétique mais elle est très peu représentative des conditions réelles de circulation. En effet, cette vision du cycle parfaitement connu est idéale puisqu'un parcours est soumis à des facteurs aléatoires tel que le trafic. Il existe alors deux méthodes qui permettent de travailler en temps réel. Il s'agit de la reconnaissance de cycle et de la prédiction de cycle. La première méthode est basée sur une analyse du parcours qui est en train de se dérouler sur une durée précise (les x dernières secondes). La prédiction de cycle va anticiper les conditions à venir, en se basant sur une analyse des conditions passées et/ou présentes, et utiliser les statistiques et probabilités pour déterminer les conditions futures.

Une méthode de reconnaissance de cycle particulièrement intéressante est proposée par V. Larsson et al. [95]. Elle consiste à analyser le parcours réalisé et à comparer les données à une base de données existantes. Le facteur de corrélation ("cross-correlation factor") détermine alors quel trajet va être effectué, ce qui permet d'adapter la gestion énergétique. Pour cela plusieurs paramètres sont relevés (tableau 1.6).

L'algorithme de reconnaissance s'effectue donc en trois étapes. Au démarrage, les coordonnées GPS (Global Positioning System) et l'heure de départ sont relevés, et tous les trajets dont le point de départ se trouve dans un rayon défini $[x_0-d^*; x_0+d^*]$ et un créneau horaire défini $[t_0-T; t_0+T]$ sont considérées comme de potentiels trajets. Durant la phase de roulage du véhicule, une boucle en temps réel s'effectue. Elle a pour but de déterminer le facteur de corrélation entre les routes candidates et la route empruntée, en se basant sur l'évolution des coordonnées GPS. Et enfin pour qu'une route soit sélectionnée comme reconnu, il faut que le coefficient de corrélation soit supérieur au critère fixé et que la distance parcourue soit supérieure à une distance minimale. Ce deuxième critère a été mis en place pour éviter une fausse corrélation avec un ensemble de données trop petites i.e. trop tôt dans le trajet. Enfin dans l'hypothèse où deux trajets respectent ces conditions, le trajet le plus court est sélectionné.

Si l'on s'intéresse maintenant à la prédiction de cycle, C. Quigley et al. [91] ont cherché à démontrer le caractère prédictif des trajets quotidiens. Pour cela, ils ont effectué des






FIGURE 1.9 – Cycle NEDC




(a) Cycle FTP-75




(b) Cycle HWFET

FIGURE 1.10 – Cycles standards américains



(a) Cycle JP10-15



(b) Cycle JC08

FIGURE 1.11 – Cycles standards japonais

relevés sur des véhicules durant 1 mois. La population de l'étude comportait 10 véhicules choisis suivant le sexe et l'âge du conducteur principal, pour être représentatif de la population de conducteur du Royaume-Uni. Les relevés sont effectués grâce à un récepteur GPS placé dans le véhicule et connecté à un PC portable. A partir du tracé de vitesse en fonction du temps, cinq paramètres importants peuvent être déterminés : le besoin en énergie, l'énergie récupérable au freinage, le temps passé à l'arrêt, la distance et la durée du trajet. La première partie de l'analyse considère que la seule variable nécessaire à la prédiction est l'heure de départ, celle-ci étant facilement disponible dans un véhicule actuel. La seconde partie de l'analyse s'intéresse à l'apport des informations disponibles avec un GPS.




FIGURE 1.12 – Cycles Artemis




FIGURE 1.13 – Cycles réels considérés par certains auteurs pour la validation de la gestion énergétique

L'analyse des données montre que les trajets du week-end sont imprédictibles c'est pour-

TABLE 1.6 – Données permettant de caractériser une route [95]

Data type	Symbol	Unit
Index	k	1,2,...,N
Distance	z_k	km
Latitude, Longitude	x_k, y_k	dec.
Start Time, Mean / Std	$\bar{t}_0, \sigma_{t_0}$	hh :mm :ss
Route Length, Mean / Std	$\bar{z}, \sigma_z$	km
Route Energy, Mean / Std	$\bar{E}_N, \sigma_{E_N}$	MJ




FIGURE 1.14 – Relation entre durée, distance et heure de départ [91]

quoï seules les données caractérisant les trajets de semaines sont présentées. Pour ces derniers, la relation entre la durée, la distance et l'heure de départ est présentée sur la figure 1.14. Des règles du type SI (l'heure de départ est ...) ALORS (la durée du trajet est de ...) ET (la distance est de ...) peuvent être mises en place et aider la stratégie à optimiser la répartition de puissance.

L'analyse de l'heure de départ est donc intéressante, mais ne semble pas encore suffisante pour optimiser au mieux la gestion énergétique d'un véhicule. C'est pourquoi les auteurs se sont intéressés aux informations que peut fournir un GPS et plus particulièrement à la position de départ. Les résultats démontrent qu'il existe certains lieux qui sont fréquemment atteints, à un diamètre près qui caractérise le lieu de parking ou le bruitage des données GPS (figure 1.15a). Grâce à une analyse nodale, il est possible de visualiser le nombre d'occurrences des trajets (figure 1.15b).

En combinant les informations des deux analyses précédentes, il est possible de prédire l'énergie nécessaire pour le trajet comme le montre la table 1.7. Cela permet de mettre en place des règles du type SI (le jour est en semaine) ET (le lieu de départ est ...) ET (l'heure de départ est...) ALORS (l'énergie nécessaire au trajet est d'environ ...). Cependant, pour certains trajets l'énergie nécessaire est assez variable. Par exemple, la variation pour les deux trajets les plus parcourus est respectivement de 18% et 29%. Ceci est probablement dû aux conditions de trafic qui peuvent être variables. Cette étude démontre que la prédiction des trajets est possible, et met en avant l'importance de tenir compte des conditions de trafic pour augmenter la précision si l'on souhaite faire de la prédiction de cycle.




FIGURE 1.15 – Prédicibilité du trajet suivant la position de départ [91]

Il existe une méthode d'optimisation appelée "colonie de fourmi", dont le principe paraît cohérent avec la reconnaissance de cycle. Cette méthode s'appuie sur le principe de fonctionnement d'une colonie de fourmi lorsqu'elle cherche de la nourriture. Un schéma présente la méthode sur la figure 1.16. Plusieurs fourmis appelées éclaireuses partent chacune dans une direction différente, laissant derrière elle une quantité de phéromones⁶. Celle qui trouvera la nourriture la plus proche reviendra en première au nid et le chemin emprunté aura donc la plus grande quantité de phéromones. Les suivantes emprunteront donc le même chemin (figure 1.16a). De plus, dans l'hypothèse où un obstacle survient en cours de trajet (chute d'un arbre par exemple figure 1.16b), les fourmis le contourneront dans un premier temps dans les deux sens possibles (figure 1.16c). Puis le chemin le plus court aura plus de phéromones après le passage d'une fourmi et par conséquent, le chemin le plus court sera toujours emprunté. Les phéromones mettent un certain temps mais finissent par disparaître. Le chemin le plus long est alors effacé (figure 1.16d).

Pour l'instant, cette méthode a été utilisée principalement pour résoudre des problèmes de type voyageur de commerce⁷. Toutefois, il paraît pertinent de l'utiliser pour faire de la reconnaissance de cycle puisqu'en appliquant le principe aux routes empruntées par l'automobiliste, il est possible de prédire le trajet qui sera effectué grâce à la quantité de phéromones restantes. De plus, cette méthode permet d'effacer de la base de données les trajets uniques (trajet pour les vacances par exemple).

L'utilisation d'un cycle pour valider une stratégie et obtenir sa performance est obligatoire. Aucun cycle n'étant considéré comme référence, un choix devra être fait. Il consiste à utiliser deux cycles différents pour la validation, un premier de type standard normalisé, et un second représentatif de conditions de roulage réelles. Pour ce dernier, deux possibilités existent : créer un cycle mixte à partir de portions de cycles existants ou effectuer des relevés pour définir un cycle représentatif. Dans ce travail, la deuxième possibilité sera adoptée et fera l'objet d'un chapitre.

6. substance chimique comparable aux hormones émises par les animaux pour transmettre aux autres individus des informations.

7. Le problème du voyageur de commerce consiste à trouver le chemin le plus court pour se rendre dans plusieurs villes sans repasser par une ville déjà visitée.

TABLE 1.7 – Trajets et besoin en énergie [91]

Journey	Mean energy (joules)	Std. Deviation (joules)	Std. Dev. as a %
A to C	5,178,192.70	947,986.64	18.3%
C to A	5,208,464.86	1,528,553.76	29.3%
B to C	-	-	-
C to B	2,389,878.75	78,878.00	3.3%
A to B	2,178,160.93	155,503.31	7.1%
B to A	2,522,6667.33	210,262.89	8.3 %




FIGURE 1.16 – Principe de fonctionnement d'une colonie de fourmis [117]

Une fois le cycle choisi pour l'évaluation, il reste à savoir comment il va être renseigné au système de gestion énergétique. Trois options peuvent être utilisées. La première consiste à renseigner le trajet, la seconde à faire de la reconnaissance de cycle et la dernière à faire de la prédiction. La première solution est à écarter si l'on souhaite être le plus représentatif possible de la réalité. En effet, dans la vie courante il est rare qu'un automobiliste renseigne au GPS ses trajets au quotidien (pour aller travailler ou faire ses courses par exemple). Toutefois, si le trajet est renseigné sur le GPS (par exemple pour les vacances), les informations seront directement utilisées par le système de gestion. Ces deux cas sont complémentaires. Au final, il a été fait le choix d'utiliser une méthode de prédiction de cycle. Initialement, le principe des algorithmes de colonie de fourmis a été retenu, avant d'être remplacée, faute de temps, par une autre méthode présentée dans le chapitre suivant.

1.2.4/ MODÉLISATION DU VÉHICULE

La modélisation du GMP d'un véhicule permet de simuler et prédire son comportement. Lorsque l'on souhaite mettre en place une stratégie de gestion énergétique d'un GMP hybride, il est nécessaire de s'appuyer sur un modèle numérique pour intégrer ses spécificités.

Il existe deux méthodes de modélisation : la méthode quasi statique et la méthode dynamique (figures 1.17 et 1.18). Elles sont toutes les deux étudiées et comparées dans l'étude de T. Nüesch et al. [81]. La première considère que le cycle considéré est suivi, et le divise en sous partie, généralement de 1s. Une méthode statique est alors utilisée en considérant que sur ce laps de temps la vitesse, le couple et l'accélération sont




FIGURE 1.17 – Flux d'informations dans un modèle dit "backward" [87]

constants. Les composants sont eux modélisés par une cartographie de rendement, de perte ou de consommation. Le point de fonctionnement est alors déterminé en partant de la puissance nécessaire aux roues et en remontant la chaîne de traction composant par composant. Les modèles dynamiques considèrent eux les équations dynamiques de chaque composant et la vitesse est déterminée comme une fonction de la force délivrée par les modes de propulsion.

Dans un modèle quasi-statique, le véhicule respecte exactement le cycle considéré, tandis que dans un modèle dynamique, la partie concernant le conducteur peut entraîner une légère déviation. Le cycle renseigné peut tout à fait être réalisable pour le véhicule considéré et là encore, la méthode dynamique possède la faculté de tenir compte des limites physique de chaque composant, contrairement à la méthode statique. Cette dernière assure obligatoirement le cycle demandé et ce n'est qu'à la fin de la simulation qu'il est possible de vérifier si les limites ont été respectées. Pour illustrer ces propos, on peut prendre l'exemple d'une accélération de 20 km/h à 130 km/h en 1 s peut être simulé grâce à une méthode quasi statique puisque ce sont deux points de fonctionnement qui ne sont pas hors des limites d'un moteur conventionnel. Toutefois, ceci n'est pas physiquement réalisable. D'un point de vue gestion énergétique, les modèles dynamiques sont préférés car ils conservent le principe de causalité du système réel et permettent de considérer les mêmes entrées et sorties [104].

De nombreux outils existent pour simuler le comportement d'un véhicule hybride et évaluer sa gestion énergétique. Certains reposent sur l'approche quasi-statique (PSAT [78, 118, 135], ADVISOR [19, 59, 68], QSS Toolbox⁸ [41]), d'autres sur l'approche dynamique (Representation Energetique Macroscopique (REM) [7, 27], PSIM [17] et V-elph⁹).

8. PSAT, QSS toolbox sont des toolbox de Matlab, ADVISOR (Advanced Vehicle Simulator) est un logiciel commercial

9. La REM est une approche dynamique tandis que PSIM et V-elph sont des logiciels commerciaux




FIGURE 1.18 – Flux d'informations dans un modèle dit "forward" [87]

1.2.5/ CRITÈRES ADOPTÉS POUR ÉVALUER LES STRATÉGIES

Pour juger des performances d'une stratégie, il est nécessaire de l'évaluer. Pour ceci, il faut d'une part un élément de comparaison et d'autre part un critère d'évaluation. L'élément de comparaison appartient systématiquement à une méthode d'optimisation globale. Dans la littérature, la Dynamic Programming (DP) et le Pontryagin's Minimum Principle (PMP), sont utilisées comme référence pour caractériser les performances des autres stratégies.

La DP a été proposée par Bellman dans les années 1950 pour résoudre les problèmes de contrôle optimal des systèmes dynamiques non linéaires [137]. C'est la méthode qui permet d'obtenir une solution globalement optimale, et ce, quelque soit la situation considérée. Son principe repose sur la décomposition du problème en sous-problèmes en le discrétisant temporellement. En effet, le principe d'optimalité de Bellman consiste à dire que cette décomposition est possible et que la solution optimale de chaque sous-problème est optimale pour le problème global. Connaissant alors l'état final souhaité, il est possible d'obtenir la solution en procédant de manière rétro-active. Le principe est illustré sur la figure 1.19. Pour cela, il faut néanmoins que le cycle soit connu a priori, ce qui rend la méthode non adaptée à d'éventuelles perturbations du cycle. La conduite en conditions réelles étant fortement soumise à des facteurs aléatoires tels que le trafic ou les conditions météorologiques, il semble dès lors difficile d'utiliser une telle méthode en temps réel. D'autant plus que cette méthode nécessite des ressources informatiques importantes et son temps de calcul est élevé. Toutefois, étant donné que la solution obtenue représente l'optimum mathématique, elle est couramment utilisée comme référence pour caractériser les performances des autres stratégies [66, 102, 105].

En ce qui concerne les critères d'évaluations, il n'y a pas de consensus. Cependant, il en existent trois que l'on retrouvera par la suite dans l'analyse détaillée des articles.




FIGURE 1.19 – Principe de la programmation dynamique, exemple sur un cas de 4 étapes [86]

Le premier concerne la consommation carburant exprimée en L ou en L/km. Le second concerne l'autonomie du véhicule par unité de carburant exprimée en km/L ou mpg (miles per gallon). Enfin, le dernier que l'on nommera critère multi objectifs dans la suite de ce chapitre, s'intéresse à la réduction d'une fonction coût, qui représente la consommation mais aussi les émissions polluantes (équation 1.1). Dans cette équation, fuel représente la consommation d'énergie (carburant dans le cas d'un véhicule hybride avec source d'énergie thermique), NO_x et PM les émissions, et x et y sont des variables définies par les auteurs. La performance est exprimée en g/mile.

$$performance = fuel + x.NO_x + y.PM \quad (1.1)$$

1.3/ STRATÉGIES DE CONTRÔLE

Une stratégie de contrôle, dans le domaine des véhicules hybrides, est un algorithme dont l'objectif est de réguler la répartition de puissance provenant des différents organes de propulsion. Les données d'entrée considérées sont les conditions d'opération du véhicule telles que la vitesse, l'accélération ou encore le couple demandé par le conducteur. Les données récupérées en sortie peuvent être l'activation ou non de certains composants, l'augmentation ou la réduction de puissance en sortie ou la modification des plages de fonctionnement [42]. Une stratégie de gestion énergétique peut être mise en place pour satisfaire différentes demandes. Les plus courantes sont d'assurer la demande de puissance du conducteur, de maintenir l'état de charge (State Of Charge (SOC)) de la batterie, de diminuer le nombre de démarrages, d'optimiser le rendement de la chaîne de traction ou bien de réduire la consommation et les émissions polluantes. Généralement, elle doit trouver un compromis pour atteindre plusieurs de ces objectifs simultanément [112, 127]. Depuis peu, l'agrément de conduite est aussi considéré, c'est à dire assurer la souplesse du changement de rapport et minimiser les vibrations [34].

La stratégie varie suivant le type d'hybridation considéré. En effet, si l'on considère un HEV, l'objectif est d'avoir un SOC final égal au SOC initial. Si l'on considère un PHEV,

il est préférable de recharger la batterie sur le réseau plutôt qu'à l'aide du moteur thermique. Par conséquent, le SOC final devra être le plus proche possible du seuil minimum toléré. Une méthode classique consiste à faire fonctionner le véhicule en mode tout électrique jusqu'à atteindre le seuil minimum puis à maintenir l'état de charge. Cette méthode présentée sur la figure 1.20 est appelée Charge Depleting/Charge Sustaining (CD/CS). Cependant, elle n'est pas la plus adaptée [39, 40, 131]. Pour obtenir une solution optimale, le principe consiste à décharger progressivement la batterie et atteindre le seuil minimum à la fin du trajet [40]. Cette méthode se trouve souvent dans la littérature sous le terme de méthode mixte (blended mode). C. Silva et al. [106] ont étudié les facteurs des PHEV affectant la consommation et les émissions de ce type de véhicule.




FIGURE 1.20 – Principe du CD/CS et de la méthode optimale pour un PHEV (en rouge la courbe du CD/CS et en bleu la courbe de la méthode optimale)[40]

Depuis peu, avec le développement des systèmes embarqués dans les voitures, il est possible d'accéder à de nombreux autres paramètres. Les technologies comme le GPS, le GIS (Geographical Information System) et l'ITS (Intelligent Transport System) permettent de définir un trajet et les conditions de trafic en temps réel [40]. Plusieurs stratégies ont besoin de connaître le cycle pour fonctionner mais certaines peuvent être utilisées sans connaissance préalable. En général, ces dernières ont été paramétrées sur un cycle prédéfini, et leur efficacité est meilleure sur celui-ci. Partant de ce constat, certains ont mis en place des stratégies de reconnaissance de cycle, qui vont utiliser les données du présent et du passé pour déterminer la stratégie [66, 94, 95]. Quelques études se sont aussi intéressées à la prédiction de cycle, en utilisant par exemple les chaînes de Markov [54, 104, 110, 113]. Dans ce cas là, l'efficacité de la stratégie va dépendre directement de sa capacité à prédire les événements futurs. L'intégration des informations disponibles via les nouvelles technologies apparaît donc intéressante pour abaisser les émissions et les consommations [67, 77].

Les stratégies de gestion se décomposent en deux grandes familles, les méthodes basées sur des règles et les méthodes d'optimisation. Il existe de nombreuses études qui ont été menées sur chacune des deux familles. P. Zhang et al. [137] établissent une revue d'ensemble des stratégies de contrôle existantes (figure 1.21). Pour cela, ils ont mené une étude bibliométrique basée sur les publications référencées dans les bases de données Science Citation Index Expanded et Conference Proceedings Citation Index-Science. Leur étude exclue les véhicules hybrides à pile à combustible et à panneau solaire. La figure montre qu'il existe davantage de méthodes d'optimisation (branche c) que de méthodes basées sur des règles (branche b), respectivement 33 méthodes contre 9.

La distribution quantitative et la distribution temporelle des études menées sur chaque stratégies, est présentée respectivement sur les figure 1.22 et figure 1.23. Cela permet d'avoir une indication sur les méthodes qui ont été étudiées. Le nombre d'articles publiés chaque année est aussi présenté dans les travaux de A. Panday et H.O. Bansal [84] et de D. Chrenko et S. Gan [29].

La tendance évoquée précédemment se retrouve sur la figure 1.22 puisque le nombre de publications est de 326 pour la branche (c) contre 189 pour la branche (b). La figure 1.23 permet de voir que trois stratégies sont privilégiées depuis une dizaine d'années. Il s'agit des règles déterministes (logic), de la logique floue et de la programmation dynamique (DP). A elles seules, elles représentent 66% des publications.

Dans la suite de ce chapitre, les méthodes basées sur des règles (branche b), qu'elles soit déterministes (branche d) ou basées sur la logique floue (branche e), seront détaillées. De même, du côté des méthodes d'optimisation (branche c), l'Equivalent Consumption Minimization Strategy (ECMS), le Model Predictive Control (MPC) et les réseaux de neurones (NN) seront décrites pour la partie optimisation en temps réel (branche f), et la DP, le principe de minimum de Pontryagin (PMP) et les algorithmes génétiques (Genetic Algorithm (GA)) seront présentées pour la partie optimisation globale (branche g). Ceci permet de couvrir près de 90% des publications parues de 1998 à 2014 et portant sur la stratégie de contrôle énergétique dans un véhicule hybride.

Concernant les 10% qui ne sont pas traitées dans ce travail, la justification de ce choix sera faite dans la sous-section méthode d'optimisation.

Y. Murphey [77] dresse un bilan de toutes les méthodes considérées comme "intelligentes" en 2008. Son travail est donc transversal et concerne plusieurs méthodes qui sont détaillées dans la suite du document, puisqu'il aborde aussi bien la programmation dynamique que la logique floue ou encore les algorithmes génétiques pour ne citer que les principaux.




FIGURE 1.21 – Présentation de toutes les stratégies employées [137]




FIGURE 1.22 – Distribution quantitative des stratégies de gestion énergétique [137]




FIGURE 1.23 – Distribution temporelle des stratégies de gestion énergétique [137]




FIGURE 1.24 – Exemple de règle déterministe

1.3.1/ MÉTHODES BASÉES SUR DES RÈGLES (BRANCHE B)

Les stratégies de gestion basées sur des règles reposent sur l'expertise des ingénieurs et l'étude des tables de rendement des différents composants. Elles sont faciles à mettre en oeuvre et fonctionnent en temps réel. La plupart des règles que l'on trouve dans la littérature sont basées sur une méthode causale. Dans le cadre d'un GMP hybride, elles définissent quand mettre en marche ou couper le moteur thermique ou permettent de déterminer la puissance électrique de charge ou de décharge de la batterie [48].

L'objectif de cette méthode consiste à faire fonctionner le système sur son point de rendement optimal. Les règles sont généralement élaborées sans connaissance préalable du cycle routier.

Il existe deux types de règles : les règles déterministes et les règles basées sur la logique floue.

Règles déterministes (branche d)

Le déterminisme est un enchaînement de cause à effet entre deux ou plusieurs phénomènes. Les règles déterministes sont donc du type "si...alors". La stratégie se résume en une analyse de scénarios. Un exemple est présenté sur la figure 1.24.

Les règles déterministes sont robustes et facilement paramétrables mais souffrent d'un manque de formalisme et de généralisation, ce qui les rend difficile à utiliser pour toutes les situations. Comme représenté sur la figure 1.21, sept stratégies différentes basées sur des règles déterministes sont reconnues.

- **thermostat (on/off)** : consiste à mettre en marche et couper le moteur pour maintenir l'état de charge entre ses limites supérieures et inférieures
- **power follower (baseline)** : considère le moteur thermique comme source primaire, le moteur électrique ne servant qu'à apporter un supplément de puissance et à recharger les batteries
- **frequency-based** : répartit la demande de puissance en basse et haute fréquence
- **engine optimal working point** : le moteur thermique fonctionne à son point de rendement optimal et le moteur électrique apporte un supplément de puissance si nécessaire
- **engine optimal operation line** : identique au power follower, et le moteur thermique va fonctionner sur sa courbe optimale sauf si le courant excède les limites du pack batterie
- **engine optimal efficiency region** : identique au deux précédents mais cette fois c'est la zone optimale considérée
- **system optimal operation point** : combine la stratégie "engine optimal operation line" avec la maximisation du rendement de la transmission

Les stratégies du thermostat et frequency-based sont généralement utilisées pour les

TABLE 1.8 – Comparaison de l'autonomie [km/l] avec la RB par rapport au PMP, au CD/CS et au véhicule conventionnel en pourcentage [123]

Driving cycle	RB vs PMP	RB vs CD/CS	RB vs ICE-only
Mixi w/grade	-8.97%	+6.01%	+52.40%
Mixi w/o grade	-4.72%	+8.16%	+54.34%
Arco Merano w/ grade	-6.04%	+9.01%	+40.03%
Arco Merano w/o grade	-7.19%	+5.94%	+52.99%
VAIL2NREL	-0.29%	+9.59%	+63.24%
Aachen	-17.5%	+3.00%	+52.80%
Moyenne	-7.45%	+6.95%	+52.63%

véhicules hybrides série. La power follower est plutôt utilisée pour les véhicules parallèles et combinés. Les quatre dernières sont utilisées sur les véhicules combinés.

L. Tribioli et al. [123], qui utilisent une règle de type thermostat, partent du constat que la stratégie CD/CS n'est pas la plus adaptée pour un PHEV, bien qu'étant fortement utilisée. La stratégie mixte utilisée par les auteurs consiste à décharger la batterie progressivement jusqu'à atteindre le minimum tolérable en fin de cycle. Les auteurs ont simulé le comportement d'une Chevrolet Malibu sur différents cycles en résolvant le problème de contrôle optimal à l'aide du PMP. Cependant, cette méthode d'optimisation globale n'est pas utilisable en temps réel puisqu'elle nécessite de connaître le déroulement du trajet. De cette étude sont donc extraites les règles qui permettent de mettre en place une stratégie en temps réel.

Les règles, qui régissent la stratégie, sont pilotées par la consigne d'écart de vitesse et par le SOC de la batterie, puisque celui-ci doit être compris entre 30 et 95%. Proche de la limite haute, le véhicule va basculer en mode électrique pour décharger la batterie. Proche de la limite basse, le moteur électrique ne sera pas utilisé et le moteur thermique rechargera les batteries en délivrant une puissance supérieure à la puissance demandée. La validation des règles a été effectuée sur différents cycles spécifiques (tableau 1.8), avec (w) ou sans (w/o) prise en compte de la pente, et sur deux cycles choisis pour leur différence prononcée avec les cycles normalisés. La méthode de Rule-Based (RB) utilisée (figure 1.25) est performante puisque l'écart avec la PMP est de 7,5% en moyenne.

Dans l'article de C. Lin et al. [66], les auteurs s'attachent à comparer la performance d'une stratégie de règles "single-mode" et "multi-mode". Le "single-mode" correspond à une stratégie unique basée sur des règles optimisées par DP pour un cycle imposé (UDD-SHDV¹⁰). Le "multi-mode" correspond à une combinaison de six stratégies de règles suivant le type de cycle rencontré, optimisée par DP pour six profils de conduite différents choisis par les auteurs.

Le choix de la stratégie à utiliser en temps réel pour le "multi-mode" est déterminé par un algorithme de reconnaissance de cycles. Deux hypothèses sont faites : les conditions de conduite ne changent pas brutalement, et les six stratégies de règles sont suffisamment différentes (pas de redondance). L'algorithme de reconnaissance de cycle est développé en partant de l'hypothèse que la puissance moyenne, l'énergie de freinage et le ratio de temps à l'arrêt par rapport au temps total, sont suffisants pour définir un profil de conduite (figure 1.26). Ces données sont extraites à chaque instant en considérant les 150 dernières secondes. Ce sont donc les données du passé qui sont utilisées pour déterminer

10. FTP72 pour les poids lourds




FIGURE 1.25 – Gestion énergétique de L. Tribioli et al. [123]

les conditions à venir. Des simulations ont été réalisées pour démontrer les performances de cette méthode. De manière globale, les résultats démontrent qu'une stratégie "multi-mode" est plus performante de 2% seulement qu'une "single-mode", mais qu'elle reste beaucoup moins performante que la DP (-22% tableau 1.9). La seule exception concerne le cycle UDDSHV pour lequel la méthode "single-mode" a été optimisée par DP justifiant sa performance par rapport au multi-mode.

TABLE 1.9 – Résultats de la simulation (fuel + 40.NOx + 800.PM [g/mile]) [66]

	UDDSHDV	WVUCITY	WVUSUB	WVUINTER	NYCCOMP	NYCTRUCK	Manhatta
Single mode	793.16	494.12	582.18	896.00	401.17	667.70	786.74
Multi-mode	801.64	468.38	576.39	897.22	381.89	659.63	771.00
DP	739.56	403.58	526.67	847.67	312.14	551.91	592.23

Une troisième méthode d'optimisation de règles est utilisée dans l'article de M. Sorrentino et al. [109]. Il s'agit des GA. Les résultats obtenus sont comparés à la DP et une différence de 3,5% est observé, ce qui valide l'utilisation des GA comme méthode d'optimisation.

Les règles déterministes sont faciles à mettre en place et permettent d'assurer la propulsion du véhicule dans toutes les situations. Cependant, lorsqu'elles sont issues de l'expertise des ingénieurs, elles sont éloignées de la solution optimale. C'est pourquoi de nombreux auteurs utilisent une méthode d'optimisation hors ligne, dont les deux principales sont la DP [66, 25] et le PMP [123], pour améliorer les performances de cette méthode. Cette optimisation est faite pour un cycle spécifique. Pour être représentative des conditions réelles d'utilisation d'un véhicule, la performance de la méthode optimisée doit alors être jugée sur un cycle inconnu. On s'aperçoit alors qu'une méthode basée sur des règles déterministes, même optimisée, restent éloignées de la solution optimale.

Logique floue (branche e)

La logique floue est une extension de la logique classique aux raisonnements approchés. Au delà de l'algèbre de Boole, la logique floue remplace la valeur de vérité d'une proposition à choisir dans {vrai, faux} par un degré de vérité, à choisir par exemple dans




FIGURE 1.26 – Gestion énergétique "multi-mode" de C. Lin et al. [66]

[0, 1]. En logique floue, il y a donc des degrés dans la satisfaction d'une condition (figure 1.27). La spécificité de cette stratégie réside dans la formulation des règles qui sont énoncées en langage naturel comme le montre l'exemple de la table 1.10.




FIGURE 1.27 – Comparaison entre la logique classique (à droite) et la logique floue (à gauche) pour la réponse à la question "la vitesse est elle élevée ?"

Le principal avantage de la logique floue est sa robustesse face aux imprécisions de mesures et aux perturbations. De plus, elle est facilement paramétrable, ce qui la rend adaptable à tous les scénarios [42].

Un contrôleur de logique floue est composé de quatre parties [88] : une base de données, une base de règles, un moteur d'inférence et la défuzzification¹¹. La base de données va servir à transformer les variables définies en variable floue (fuzzification). La base de règles est constituée de règles formulées le plus souvent sous la forme "si...alors" [108]. Le mécanisme d'inférence va décider de la règle à utiliser parmi la base de règles en s'appuyant sur les données floues qu'il reçoit en entrée. Enfin, la défuzzification va transformer les règles obtenues par l'inférence en variable définie, pour que le système prenne une décision. Pour des informations plus avancées sur le contrôle flou, le lecteur pourra se référer au livre de H.T. Nguyen et M. Sugeno [32].

L'analyse des articles montre que les stratégies basées sur la logique floue sont très souvent optimisées par un GA hors ligne pour obtenir une solution proche de la solution optimale.

A. Ravey et al. [94] utilisent la logique floue comme stratégie de contrôle pour un véhicule hybride pile à combustible/batterie (figure 1.29). Le contrôleur de logique floue a pour entrée deux variables floues : l'état de charge et le type de cycle.

11. transformation d'une variable floue en une variable définie

TABLE 1.10 – Exemple de règles de logique floue

Si le feu est rouge	si ma vitesse est élevée	et si le feu est proche	alors je freine fort
Si le feu est rouge	si ma vitesse est faible	et si le feu est loin	alors je maintiens ma vitesse
Si le feu est orange	si ma vitesse est moyenne	et si le feu est loin	alors je freine doucement
Si le feu est vert	si ma vitesse est faible	et si le feu est proche	alors j'accélère

Les auteurs étudient trois stratégies basées sur trois contrôleurs de logique floue différents :

- un "urbain" paramétrisé pour un cycle urbain spécifique, le LA92
- un "autoroutier" paramétrisé pour un cycle autoroutier non spécifié par les auteurs
- un "mixte" avec détection de cycle (Driving Cycle Recognition Algorithm (DCRA))

Dans le cas du DCRA, le type de cycle est obtenu à l'aide d'un algorithme de reconnaissance de cycle (figure 1.28), et peut avoir comme état : urbain, extra urbain ou autoroutier. Le DCRA va adapter la stratégie au trois profils de cycle. Quant à l'état de charge, il peut avoir quatre niveaux : bas, optimal, haut ou très haut. Les auteurs ont comparé les performances des trois contrôleurs pour deux cycles différents : LA 92 et custom cycle (tableau 1.11).

Des simulations sur deux parcours mixtes sont effectuées, et les résultats mettent en évidence l'importance de l'algorithme de reconnaissance de cycle. Lorsque l'algorithme est utilisé, un gain de 14% est observé par rapport au contrôleur de logique floue "autoroutier". Cependant, Le contrôleur de logique floue "urbain" donne de meilleurs résultats que le DCRA pour trois des quatre situations simulées, montrant les limites de l'algorithme de reconnaissance du cycle.

A. Hajizadeh et M. Golkar [43] ont mené une étude similaire portant sur la gestion énergétique d'un véhicule hybride pile à combustible/batterie. La différence réside dans le choix de la règle à utiliser qui dans leur cas est déterminé grâce à une méthode de réseau de neurones. De même, A. Ivanco et al. [52] se sont eux aussi intéressés à la reconnaissance de type de route et ont développé plusieurs stratégies basées sur celle-ci.




FIGURE 1.28 – Principe de l'algorithme de reconnaissance de cycle [94]

A. Neffati et al. [80] ont mis en place une stratégie qui sélectionne en temps réel les règles

TABLE 1.11 – Résultats des trois types de contrôleurs sur le LA92 et sur un cycle mixte [94]

Driving cycle	Parameters of fuzzy controller	Final SOC	Hydrogen consumption (g)
LA92 cycle	Urban	0.752	73
	Highway	0.7	98
	DCRA	0.72	73
Custom cycle	Urban	0.56	168
	Highway	0.62	212
	DCRA	0.6	179
Custom cycle ran 5 times	Urban	0.28	1015
	Highway	0.6	1252
	DCRA	0.45	1143
Custom cycle ran 10 times	Urban	Not finished	Not finished
	Highway	0.6	2556
	DCRA	0.4	2365




FIGURE 1.29 – Gestion énergétique avec DCRA de A. Ravey et al. [94]

à utiliser pour s'adapter au type de route emprunté par l'automobiliste (figure 1.31). Trois règles sont mises en place et optimisées par un GA hors ligne :

- Rule 1 : conçu pour un profil urbain
- Rule 2 : conçu pour un profil extra-urbain
- Rule 3 : conçu pour un profil autoroutier

L'algorithme de basculement de règles (appelé Fuzzy Switching of Fuzzy Rules (FSFR) par les auteurs) considère comme données d'entrée la puissance instantanée demandée ainsi qu'une moyenne des trois dernières puissances utilisées (figure 1.30.b). Ces deux données d'entrée peuvent avoir trois niveaux variables (puissance basse, moyenne ou haute). Ces derniers sont aussi optimisés par GA. Avec ces données, la règle la plus adaptée est extraite et utilisée. Le système d'inférence utilisé est présenté dans la table 1.12. Enfin, en récupérant le SOC du système de stockage, la puissance que doit délivrer la pile à combustible est déterminée (figure 1.30). La validation a été réalisée par




FIGURE 1.30 – Gestion énergétique avec basculement de règles [80]

TABLE 1.12 – Système d'inférence du contrôleur de logique floue [80]

Power-Index	Low	Average	High
Low	Rule 1	Rule 1	Rule 2
Average	Rule 1	Rule 2	Rule 3
High	Rule 2	Rule 3	Rule 3

simulation en considérant un véhicule hybride parallèle composé d'une pile à combustible et d'une super-capacité. Le cycle considéré est le cycle INRETS qui est inconnu du système adaptatif. Les résultats sont présentés dans la table 1.13. Le FSFR présente donc de très bon résultats par rapport une règle optimisée par GA spécifiquement pour le cycle INRETS, puisque la différence est de seulement 0.8%. Cette règle n'est cependant pas optimale puisqu'elle est optimisée par une stratégie sous optimale. Les résultats du FSFR sont moins bon de 18% en moyenne par rapport à l'IDP qui est la solution optimale (tableau 1.14).

Dans leur article J. Won et R. Langari [129] développent un agent de gestion intelligente d'énergie appelé Intelligent Energy Management Agent (IEMA), qui est piloté par une combinaison d'informations telles que l'état du véhicule, la demande de puissance ou encore l'analyse en temps réel du cycle de conduite. Il est présenté sur la figure 1.32. Le but de l'IEMA est de gérer la répartition d'énergie en identifiant la situation de conduite et en délivrant ces informations au système décisionnel. Pour cela, il est divisé en quatre sous agent :

- le DIE (Driving Information Extractor) : extrait des données statistiques ou des paramètres caractéristiques du mode de conduite
- le FTD (Fuzzy Torque Distributor) : détermine le couple
- le SC (State of charge Compensator) : assure le maintien de l'état de charge de l'élément de stockage durant le trajet
- le DSII (Driving Situation Identifier) est divisé en quatre sous partie :
 - le RTI (Roadway Type Identifier) : détermine le type de route et le trafic routier sur les 100 à 150 dernières secondes
 - le DTI (Driving Trend identifier) : détermine la tendance actuelle de conduite en se basant sur les conditions de conduite à court terme

TABLE 1.13 – Résultats et comparaison entre règle optimale et basculement de règles [80]

Method	Optimal rule	Rule 1	Rule 2	Rule 3	FSFR
Cost (kW _s)	9388	9525	9628	9542	9466

TABLE 1.14 – Résultats et comparaison entre IDP et basculement de règles [80]

Method		Urban	Roads 2	Highway 3	INRETS
UB	Cost (kW _s)	5815	15451	23084	15903
DP	Cost (kW _s)	5312	12341	20012	9881
	Gain vs UB	9%	20%	13%	38%
IDP	Cost (kW _s)	2298	9945	18800	8718
	Gain vs UB	60%	36%	19%	45%
FSFR	Cost (kW _s)	3390	11030	19732	9466
	Gain vs UB	42%	29%	15%	40%
	Gain vs IDP	-48%	-11%	-5%	-9%

- le DMI (Driving Mode Identifier) : détermine les intentions de conduite du pilote (dé-marrage, accélération, décélération, arrêt)
- le DSI (Driving Style Identifier) : caractérise le style de conduite

Trois styles de conduite ont été identifiés : calme, normal et agressif, tous trois différenciés par la moyenne de l'accélération. Le DIE et le DSII sont des agents informateurs alors que le FTD et le SC sont des agents décisionnels. Trois temps caractéristiques sont pris en compte (figure 1.33) :

- T_{lt} : temps caractéristique des données du DSI et du RTI (lt pour long terme)
- T_{st} : temps caractéristique des données du DTI (st pour court terme ("short term"))
- T_{iu} : période de mis à jour du type de route et du style de conduite

Une simulation d'un véhicule parallèle sur le cycle UDDS a été réalisé pour démontrer l'intérêt d'un tel agent de gestion. Les résultats sont présentés sur la figure 1.34. L'agent de gestion intelligente permet une amélioration de 2% à 5% d'énergie sur le cycle considéré.

Les stratégies basées sur des règles de logique floue présentent les mêmes avantages que les règles déterministes. Elles sont faciles à mettre en place et ne nécessitent pas la connaissance du cycle. Mais contrairement aux règles déterministes, elles sont tolérantes aux imprécisions de mesures ce qui les rend particulièrement adaptées aux systèmes non linéaires. Cependant, elles sont nécessairement sous optimale et, même si elles sont souvent optimisées par GA dans la littérature [20, 56, 80], elles restent sensibles au cas considéré. Les résultats obtenus en utilisant ce type de méthode sont éloignés de la solution optimale dès lors que le cycle est inconnu. Dans la littérature, il existe d'autres méthodes d'optimisation telles que DIRECT ([62, 99]), mais elles sont plus rares et ne donnent pas de meilleurs résultats.




FIGURE 1.31 – Gestion énergétique de A. Neffati et al. [80]




FIGURE 1.32 – IEMA architecture [129]




FIGURE 1.33 – Temps caractéristiques [20]




FIGURE 1.34 – Résultats de la simulation avec et sans IEMA [20]

1.3.2/ MÉTHODES D'OPTIMISATION (BRANCHE C)

Les méthodes de contrôle basées sur l'optimisation ont pour objectif la minimisation d'une fonction coût, qui représente les exigences de performances du véhicule [137]. Elles peuvent être globales (figure 1.21(branche g)) ou en temps réel (figure 1.21(branche f)).

1.3.2.1/ MÉTHODES D'OPTIMISATION GLOBALE (BRANCHE G)

Les stratégies d'optimisation globale nécessitent la connaissance du cycle à priori, ce qui est incompatible avec un cycle de conduite réel qui est dépendant de phénomènes extérieurs tels que le trafic. C'est pour cette raison, et parce que leur coût informatique est élevé, que ces méthodes sont inutilisables pour du contrôle en temps réel. Toutefois, elles sont fréquemment utilisées lors de la phase dimensionnement des composants d'un véhicule hybride ([107, 114]).

On trouve trois sous-catégories de méthodes d'optimisation globale qui sont les méthodes d'optimisation dites statiques, les méthodes dynamiques et d'autres méthodes qui reposent essentiellement sur des modèles mathématiques permettant d'approximer le problème ("other optimization method" sur la figure 1.21(branche g)).

Les méthodes dynamiques permettent d'obtenir une solution optimale, alors que les méthodes statiques et mathématiques mènent nécessairement à une solution sous-optimal de par les approximations qu'elles font. Les méthodes statiques sont utilisées pour optimiser les paramètres des stratégies basées sur des règles. La stratégie la plus utilisée pour ce type de méthode est les GA. Elle est présentée dans la suite de la section. L'optimisation par essaim de particules (PSO) n'est pas présentée mais il existe une analogie avec les GA qui a été décrite dans plusieurs articles [35, 46, 58]. De plus, le lecteur peut se référer aux travaux de H. Banvait et al. [45] ou de X. Wu et al. [132] pour des exemples de gestion énergétique basées sur l'optimisation par PSO. Pour les méthodes dynamiques, la DP et le PMP sont détaillées. Les méthodes appelées "other optimization method" ne sont pas développées car elles ne sont pas utilisables en temps réel et sont sous-optimales. Elles ne présentent donc pas d'intérêt pour ce travail.

Algorithmes génétiques

Les algorithmes génétiques sont directement dérivés de la génétique et la sélection naturelle, qu'ils appliquent à une population de solutions potentielles au problème donné. La solution est approchée par « bonds » successifs, comme dans une procédure de séparation et évaluation, à ceci près que ce sont des formules qui sont recherchées et non plus directement des valeurs. Dans la suite de ce paragraphe, certains termes issus de la génétique vont être utilisés pour définir le processus :

- Un individu est une solution au problème
- Un gène sera une partie d'un individu
- Une population sera un ensemble d'individus
- Une génération est une itération de l'algorithme

Les algorithmes génétiques se décomposent en cinq grandes étapes [75]. La structure est présentée sur la figure 1.35.

1. Création de la population initiale




FIGURE 1.35 – Structure d'un algorithme génétique [31]

2. Evaluation de la performance de chaque individu grâce à une fonction d'évaluation ("fitness function")
3. Sélection des meilleurs individus pour la nouvelle génération
4. Recombinaison des individus par croisement ¹² et mutation ¹³
5. Evaluation des nouveaux individus et établissement de la nouvelle génération

L'algorithme se poursuit tant que l'un des trois critères d'arrêt possibles n'est pas rempli : l'algorithme a trouvé une solution qui satisfait le critère de minimum, les sorties de l'algorithme satisfont la valeur du critère d'évaluation choisie comme cible, ou, le temps de calcul dépasse le temps maximum alloué et/ou le nombre de générations est trop élevé [28].

Les algorithmes génétiques sont utilisables pour des problèmes multi objectifs [5, 51]. Toutefois, ils ne sont utilisables directement que sur des problèmes non contraints. Pour contourner cette limite, une fonction pénalité peut être incluse dans la fonction d'évaluation des solutions.

Programmation dynamique

Comme évoqué dans le paragraphe 1.3.2, la programmation dynamique permet d'obtenir une solution globalement optimale, mais son temps de calcul élevé et la nécessité de connaître exactement le trajet rendent cette méthode inutilisable en temps réel. C'est la conclusion à laquelle sont arrivés A. Brahma et al. [16] dès l'année 2000.

Lin et al. [65] ont mené une étude portant sur la Stochastic Dynamic Programming (Programmation Dynamique Stochastique) (SDP) pour s'affranchir de la dépendance au cycle

12. modification d'un gène d'un individu

13. délimitation des séquences par un gène de coupure et croisements des séquences de chaque parent

dont souffre la DP (figure 1.37). Cette méthode permet donc de résoudre le problème en temps réel. La SDP est basée sur un outil appelée "chaîne de Markov" qui permet de déterminer les conditions futures en fonction des conditions présentes uniquement. Elle est généralement utilisée sur la puissance ou la vitesse. Les coefficients de probabilités de la chaîne ont été déterminés à partir d'une étude menée sur plusieurs cycles standards, représentatifs des différents types de route. Pour comprendre le principe d'une chaîne de Markov, une matrice de probabilité est présentée sur la figure 1.36. Le graphe définit la probabilité que la variable considéré passe d'un état x à l'instant présent (Current Demand Indices) à un état y à l'instant suivant (Next Demand Indices).




FIGURE 1.36 – Exemple de matrice de probabilité de transition d'une chaîne de Markov [65]

Le problème considéré dans cette étude est multi objectifs et considère la consommation, les émissions, mais aussi la déviation du SOC réel par rapport au SOC de référence. La SDP est testée sur un véhicule hybride parallèle et comparée à une méthode basée sur des règles déterministes qui a été préalablement entraînée par DP. Pour la simulation, un modèle de véhicule est utilisé et différents cycles sont considérés. Les résultats présentés sur la table 1.15 montrent que la SDP procurent de meilleur résultats hormis sur le cycle UDDSHDV. Ceci est dû au fait que la méthode basée sur des règles a été entraînée sur ce cycle, elle est donc quasi optimale.

Sun et al. [113] utilise eux aussi la programmation dynamique stochastique pour optimiser l'utilisation des véhicules hybrides. Les auteurs utilisent une chaîne de Markov pour déterminer la futur demande de puissance et ainsi déterminer le cycle de conduite (figure 1.38). De plus, ils sont les premiers à inclure le prix de l'électricité et du carburant dans leur réflexion. L'étude a pour but de comparer la méthode CD/CS à la méthode mixte. La simulation réalisée sur deux cycles FTP-72 consécutifs chiffre un gain de 6.4% sur l'énergie totale et une économie de carburant de 8.2%.

Contrairement aux études précédentes, celle de Johannesson et al. [54] n'a pas pour but de développer un modèle de contrôle prédictif capable de fonctionner en temps réel, mais de définir ce qui peut être fait en exploitant de façon optimale les informations disponibles

TABLE 1.15 – Comparaison des résultats entre la SDP et la méthode de règles déterministes (fuel + 40.NO_x + 800.PM [g/mile]) [65]

Driving cycle	Rule-based (DDP)	SDP
UDDSHDV	793.2	794.8
WVUINTER	896.0	891.3
WVUSUB	582.2	583.4
WVUCITY	494.1	473.4
NYCCOMP	401.2	392.5
HWFET	958.7	947.9
SC03	1011.8	1001.8

dans la voiture, i.e. démontrer le potentiel du contrôle prédictif pour les HEV. Trois types de contrôleurs sont testés et évalués sur un cycle spécifique. Le premier est considéré comme idéal puisqu'il connaît exactement la future demande de puissance. Ceci permet d'obtenir une solution optimale. Le second correspond à une voiture équipée d'un GPS et d'un ITS et dont le parcours est renseigné. Le dernier contrôleur connaît le trajet mais n'a aucun retour sur sa position exacte. Cela représente un véhicule évoluant dans un environnement spécifique (par exemple urbain) et dont le contrôleur a été optimisé pour cet environnement.

Pour les deux derniers contrôleurs, une chaîne de Markov est utilisée pour déterminer la vitesse. Pour celui équipé de systèmes embarqués, la chaîne est dépendante de la position alors que pour le dernier, elle est indépendante de la position. La mission sur laquelle seront testés les contrôleurs a été réalisée au préalable 40 fois dans des conditions de conduites fluides et quatre paramètres ont été relevés : temps, position, altitude et vitesse. Les coefficients de probabilités de la chaîne de Markov sont alors déterminés en utilisant la moyenne des données relevées.

La stratégie mise en place pour les tests est la SDP et les trois paramètres d'entrée considérés sont l'accélération, le SOC souhaité et la pente de la route (figure 1.40). Le domaine pour lequel les conclusions sont applicables est large puisque les auteurs ont considérés trois types de véhicules (taxi berline, compacte et SUV) et quatre configurations (série avec une hybridation FC/batterie ou FC/SC et parallèle avec une hybridation MCI/batterie ou MCI/SC). Les résultats démontrent que pour un véhicule dont la source primaire est un MCI, le contrôle prédictif basé sur le GPS et l'ITS permet d'obtenir de 6 à 8% d'économie de carburant par rapport à un véhicule qui n'utilisent pas les informations de systèmes embarqués (figure 1.39). La comparaison avec le contrôleur idéal donne d'excellent résultats puisque la simulation ne montre aucune différence pour un véhicule MCI/batterie ou MCI/SC. Toutefois, il n'est pas possible de déduire que les auteurs ont mis en place une solution optimale en temps réel car les données relevées ont été réalisées dans les mêmes conditions de circulation (trafic fluide). Il n'y a donc pas de prise en compte de ralentissements ou de bouchons.

Cet article démontre alors qu'il est possible de mettre en place une stratégie quasi-optimale en temps réel en utilisant les données des systèmes embarqués pour améliorer la consommation des véhicules hybrides. La précision des informations extraites est dans ce cas déterminante pour la performance de la stratégie.

Concernant le problème du temps de calcul élevé, J. Pu et al. [90] ont mis en place un algorithme qui restreint la zone de recherche de solution. Cette méthode permet de




FIGURE 1.37 – Gestion énergétique de Lin et al. [65]

résoudre le problème avec un temps de calcul raisonnable bien que toujours trop élevé pour utiliser la méthode en temps réel.




FIGURE 1.38 – Gestion énergétique de Sun et al. [113]




FIGURE 1.39 – Excès de consommation par rapport au contrôleur idéal [54]. Le contrôleur avec systèmes embarqués est représenté en noir et le contrôleur indépendant de la position est représenté en gris. T8 et T9 sont les véhicules pourvus d'un MCI en source primaire.




FIGURE 1.40 – Gestion énergétique de Johannesson et al. [54]

1.3.2.2/ MÉTHODES D'OPTIMISATION EN TEMPS RÉEL (BRANCHE F)

Contrairement aux méthodes d'optimisation globale, les méthodes d'optimisation en temps réel vont chercher à minimiser une fonction coût instantanée. Ceci les rend moins coûteuse en ressources informatiques ce qui permet de les implémenter dans les véhicules. Les plus connues sont l'ECMS et le MPC qui sont respectivement l'application temps réel du PMP et de la DP [137]. Les deux méthodes sont présentées individuellement dans la suite de la section. L'Extremum Seeking (ES) et le contrôle robuste (figure 1.21 (branche f)) ne sont pas présentés car elles présentent, à l'heure actuelle, des limites qui ne sont pas compatibles avec notre travail. L'ES permet de trouver uniquement des solutions optimales localement et n'est pas multi objectifs. Et le contrôle robuste simplifie un système transitoire non linéaire en un système stationnaire linéaire, tout en conservant une complexité mathématique ce qui a freiné son développement dans l'optique de la gestion énergétique d'un véhicule hybride [137].

Equivalent Consumption Minimization Strategy (ECMS)

L'ECMS est basée sur le PMP puisque le but est là aussi de minimiser une fonction hamiltonienne mais cette fois à chaque pas de temps. Son principe consiste donc à réduire le critère global à un problème d'optimisation instantanée, en introduisant une fonction coût, qui ne dépend que des variables du système à l'instant présent [79]. La variable de sortie représente la répartition de puissance qui est notée $u(t)$ et définie par $u(t) = P_{therm}/P_{dem}$. Mathématiquement, le but de la stratégie est de réduire la consommation équivalente (équation 1.3). Celle-ci est définie comme étant la somme de la consommation en carburant $\dot{m}_f$ et de la consommation en électricité $\dot{m}_e$. pour que ces deux grandeurs soient comparables, un facteur d'équivalence, noté $s(t)$, est introduit (équation 1.4).

$$J(t) = \int_{t_0}^{t_f} \dot{m}_{eq} dt \quad (1.2)$$

$$H(x, u, t) = P_{fuel}(u, t) + s(t).P_{ech}(x, u, t) \quad (1.3)$$

$$\dot{m}_{eq} = \dot{m}_{carb} + s(t).\dot{m}_{elec} \quad (1.4)$$

Le dimensionnement de $s(t)$ est l'étape cruciale de la méthode. En effet, il aura un impact direct sur la variable de sortie et dépend directement du cycle [79, 83]. Un facteur d'équivalence peut donner de mauvaises performances ou même rendre le véhicule incapable de terminer le trajet, lorsqu'il est utilisé sur un cycle différent de celui pour lequel il a été optimisé (figure 1.41). Il faut normalement définir deux facteurs d'équivalence, l'un caractérisant la charge et l'autre la décharge. Toutefois il est possible d'obtenir des résultats quasiment identiques en utilisant un seul facteur [98]. Pour cela, il faut introduire la variable $p(t)$ qui représente la probabilité de se trouver en phase de charge. Ainsi, un seul facteur défini dans l'équation 1.5 est suffisant.




FIGURE 1.41 – Impact du facteur d'équivalence sur le niveau de SOC final pour un type de cycle différent et pour une distance différente [83]

$$s(t) = p(t)s_{charg} + (1 - p(t))s_{dech} \quad (1.5)$$

Des travaux ont été menés pour rendre la méthode adaptative en faisant varier périodiquement le facteur d'équivalence. S. Onori et L. Serrao [83] dressent un récapitulatif des possibilités existantes pour rendre l'ECMS capable de s'adapter au cours du trajet. Ils en listent trois différentes. L'adaptation peut être basée sur la prédiction du cycle de conduite, la reconnaissance des conditions de conduite ou bien sur l'évolution du SOC.

J. Bernard et al. [13] s'intéressent à l'optimisation d'un véhicule hybride pile à combustible/batterie. L'objectif est de minimiser la consommation d'hydrogène en respectant certaines contraintes telles que les limites de puissance ou la dynamique du système. Pour cela les auteurs ont mis en place une stratégie en temps réel, proche de l'ECMS et dérivée de la solution optimale (figure 1.43). L'idée de base de cette stratégie repose sur la variation périodique du facteur d'équivalence, en se basant sur la demande de puissance de la part du conducteur et l'estimation de l'écart par rapport à la consigne de SOC (figure 1.42). Toutefois, il n'est pas nécessaire de connaître la future demande de puissance mais uniquement sa distribution. Pour la déterminer, les auteurs introduisent le caractère prédictif puisqu'il est fait l'hypothèse que la distribution future de la puissance est égale à la distribution de la puissance sur les N derniers échantillons. Des algorithmes plus complexes peuvent être utilisés pour la prédiction, mais celui considéré ici est simple, peu coûteux en ressources informatiques et permet d'obtenir des résultats intéressants sur la consommation. Une étude numérique a été menée avec pour objectif de comparer les deux stratégies. Les résultats montrent que pour un ΔSOC équivalent, les consommations varient de 2 à 3% suivant le type de route emprunté.

M. Vajedi et al. [125] mettent en place une gestion énergétique basée sur le suivi d'un profil de SOC (figure 1.44). Ce dernier est généré en s'appuyant sur les informations disponibles du trajet. Trois niveaux d'informations sont considérés : aucune information, seule la longueur du trajet est connue ou bien le cycle est connu. La méthode désignée par




FIGURE 1.42 – Principe de la stratégie en temps réel [13]

TABLE 1.16 – Résultats de la consommation de carburant, en Miles Per Gallon (MPG), pour chaque stratégies de Vajedi [125]

Strategy	FHF cycle	3F cycle
Rule-based	95.1	97.7
CDCS	93.1	94.9
Manual CDCS	100.5	99.6
A-ECMS	98.3	104.7
Route based ECMS	103.4	107.7
PMP	103.8	108.4

A-ECMS n'a connaissance que de la distance du trajet tandis que la méthode désignée par "route-based ECMS" a connaissance de l'ensemble du trajet grâce aux systèmes embarqués comme le GPS. Pour effectuer la simulation deux cycles sont utilisés. Ils sont la combinaison de cycles standards puisque le cycle 3F représente une succession de 3 cycles FTP-75, et le cycle FHF représente un enchaînement FTP-75/HWFET/FTP-75. Au final les résultats de la simulation démontrent que la méthode "route-based ECMS" est moins bonne que le PMP de 0,4% seulement et au vu du gain en temps de calcul, elle semble plus intéressante étant donné qu'elle s'utilise en temps réel. Toutefois, si le trajet n'est pas renseigné sur le GPS (ce qui est souvent le cas dans la vie de tous les jours), la méthode A-ECMS est moins bonne de 4,4% en moyenne par rapport à la solution optimale.

L. Li et al. [64] utilisent une stratégie basée sur l'ECMS qui s'adapte aux conditions de conduite (figure 1.46). D'une part, une reconnaissance de cycle est mise en place en s'appuyant sur des statistiques de moyennes de vitesse et d'accélération. La décision est prise grâce à un algorithme de logique floue. D'autre part, la valeur du facteur d'équivalence est déterminée par un algorithme de colonie de fourmis. Pour la reconnaissance de cycle, les entrées considérées sont : la vitesse moyenne du cycle, la vitesse moyenne actuelle, l'accélération moyenne, la décélération moyenne et le pourcentage de temps passé à l'arrêt. En sortie il existe quatre types de cycles possibles : stop and go, urbain, suburbain ou rural. Ces quatre types de cycles ont été définis à partir d'une étude réalisée sur un bus électrique pendant 5 ans. Pour chaque cycle de conduite, les facteurs sont optimisés par colonie de fourmis par le biais d'une boucle présentée sur la figure 1.45. Grâce à cette méthode appelée *ECMS optimisée* par les auteurs, les gains en consommation sont de l'ordre de 14% par rapport à une méthode ECMS classique.




FIGURE 1.43 – Gestion énergétique de Bernard et al. [13]




FIGURE 1.44 – Gestion énergétique de Vajedi et al. [125]




FIGURE 1.45 – Cycles représentatifs et principe de la stratégie mise en place [64]




FIGURE 1.46 – Gestion énergétique de Li et al. [64]

Model Predictive Control (MPC)

Le MPC appartient à la famille de techniques de contrôle qui utilise de manière explicite un modèle du système pour obtenir le signal du contrôle qui minimise une fonction coût [18, 104]. Cette méthode a été largement utilisée pour des applications industrielles, et démontre depuis quelques années un potentiel pour la gestion énergétique de véhicule hybride [97].

La prédiction d'un cycle complet est fortement dépendante des paramètres environnementaux tels que le trafic ou la météo. L'idée de base est alors de séparer le trajet en p pas de temps, p étant appelé l'horizon de prédiction [9, 55]. La stratégie se décompose alors en quatre étapes :

1. Prédiction du trajet sur l'horizon de prédiction, en se basant sur l'état actuel du véhicule
2. Résolution du problème d'optimisation ce qui mène à une séquence de contrôles optimaux
3. Application de la première valeur de la séquence
4. Itération

Cette technique demande un modèle précis du système et des ressources informatiques importantes mais moindre que la DP [104].

Pour M. Back et al. [9], le cycle de conduite n'est pas dépendant du temps mais de la position, cela permet notamment de tenir compte des aléas du trafic. Le véhicule considéré lors de la simulation est un hybride parallèle diesel/batterie. La stratégie considérée consiste à obtenir le même état de charge à la fin qu'au début ($SOC_{final} = SOC_{initial}$) et la route est une route de basse montagne. La batterie est chargée en descente et l'énergie électrique ne propulse le véhicule que dans les portions les moins montantes. Etendre l'horizon de précision au trajet entier montre un gain potentiel de 20% sur la consommation par rapport au véhicule non hybride. Cependant ceci n'est pas envisageable puisque le cycle fait 80km. Les simulations faites avec des horizons plus petit (250 à 3000m) montrent que les économies de carburant sont moins importantes si l'horizon est petit, mais qu'elles dépendent fortement du profil de couple demandé. La gestion énergétique de Back et al. est présentée sur la figure 1.47.

L'influence de l'horizon de prédiction sur les émissions de CO_2 a été étudié par M. Debert et al. [34]. Il utilise le MPC pour prédire le futur trajet en se basant, à la fois sur les données des systèmes embarqués (GPS) et sur les données du conducteur modélisé par un couple à la roue (figure 1.48 et figure 1.49). Les voitures considérées sont des plug-ins. Différents cycles sont considérés et l'état de charge initial est de 50% alors que l'état de charge final est de 30%. Les auteurs démontrent qu'un horizon de 20s est meilleur qu'un horizon de 2s (tableau 1.17), puisqu'un horizon de 2s n'est pas suffisant pour évaluer la récupération d'énergie au freinage.

H. Banvait et al. [11] ont étudié la différence entre le MPC et la DP pour la gestion énergétique d'un PHEV. Ils démontrent que dans leur cas, l'énergie dépensée en utilisant le MPC n'est supérieur que de 4,25%, ce qui est tout à fait acceptable pour une stratégie qui permet une utilisation en temps réel.

Réseaux de neurones (NN)

Un réseau de neurones (aussi appelée réseau de neurones artificiels) est un modèle




FIGURE 1.47 – Gestion énergétique de Back et al. [9]

basé sur des données dont le principe imite le fonctionnement des neurones biologiques du cerveau [128]. Un NN est comme son nom l'indique constitué de neurones (figure 1.50). Ces neurones ont des données d'entrées (p_1 et p_2), des poids associés à chaque entrée ($w_{1,1}$ et $w_{1,2}$) et une fonction d'activation (f). Un réseau de neurones est donc constitué de trois couches qui sont présentées sur la figure 1.51a. Tout comme le cerveau, les NN nécessitent une phase d'apprentissage. Celle-ci s'effectue par expérience, il faut donc une importante base de données pour que le réseau soit confronté à toutes les situations possibles. Ceci est la limitation principale de la méthode. Dans le cas d'un véhicule hybride, les conditions peuvent changer aléatoirement et il est difficile de rencontrer tous les cas en phase d'apprentissage en laboratoire. C'est pourquoi il existe la possibilité d'inclure une boucle de rétroaction qui ajustera tout au long de la vie du véhicule les poids associés aux entrées 1.51b.

Pour plus de détails sur les réseaux de neurones, le lecteur peut se référer au travail de S. Haykin [47].

H. Chen et al. [26] ont étudié l'impact de l'absence de données sur une méthode de gestion par NN. F. Harmon et al. [44] ont, quand à eux, utilisé cette méthode pour la gestion énergétique d'un drone. Tandis que J. Moreno et al. [76] ont mis en place une gestion énergétique basée sur les NN pour un véhicule SC/batterie.




FIGURE 1.48 – Integration du contrôle prédictif dans l'environnement du véhicule [34]

TABLE 1.17 – Supplément de CO₂ pour différents cycles et une stratégie de maintien de charge à 30% [34]

Cycle/horizon (s)	2	5	10	20	30
Artemis extra-urban	4%	2.6%	2%	1.8%	1%
Artemis urban	6.6%	5.2%	4.5%	2.3%	1.2%
Artemis Traffic-jam	14.7%	5.7%	3.8%	2.3%	1.2%
NEDC	3.1%	2.3%	2%	1.5%	1%




FIGURE 1.49 – Gestion énergétique de Debert et al. [34]




FIGURE 1.50 – Neurone artificiel[128]




FIGURE 1.51 – Représentation simplifiée d'un réseau de neurones artificiels [128]

1.4/ CONCLUSION

Pour mettre en place une gestion énergétique dans un véhicule hybride, il est nécessaire de faire appel à une stratégie. Celles-ci sont nombreuses mais on distingue deux grandes catégories : les méthodes basées sur des règles et les méthodes d'optimisation. Les avantages et inconvénients de chacune de ces familles sont présentés dans la table 1.18.

TABLE 1.18 – Avantages et inconvénients des familles de stratégies

Méthodes basée sur des règles	Méthodes d'optimisation
+ Robustes + Ne nécessitent pas la connaissance du cycle + Faciles à implémenter dans un véhicule	+ Donnent la meilleure solution + Efficaces pour des problèmes multi objectifs
- Ne donnent pas une solution globalement optimale - Nécessitent d'être bien calées - Non formalisées	- Difficiles à implémenter dans un véhicule - Nécessitent la connaissance du cycle - Coûteuses en temps de calcul

Les méthodes basées sur des règles sont trop éloignées de la solution optimale si l'on n'effectue pas au préalable une optimisation hors ligne. Cette optimisation permet d'obtenir des résultats quasi-optimaux uniquement si le cycle parcouru est connu. Plusieurs études ont démontré qu'il est possible de s'affranchir de cette dépendance au cycle en optimisant les paramètres pour chaque type de route et en incluant dans la gestion énergétique un algorithme de reconnaissance de type de routes. Toutefois, la solution obtenue reste éloignée de la solution optimale. C'est pourquoi les méthodes basées sur des règles ne seront pas utilisées dans la suite de l'étude.

Parmi les méthodes d'optimisation, on trouve deux sous familles : les méthodes en temps réel et les méthodes globales. Dans le cadre de la problématique abordée dans cette étude, il est nécessaire de s'orienter vers une méthode en temps réel. De plus, si l'on considère les situations de la vie courante, peu de personnes renseignent leur destination lorsqu'ils font des trajets habituels (travail, course). C'est pourquoi la méthode retenue devra être prédictive. Cela signifie qu'il faut être capable d'anticiper le trajet de l'automobiliste. La solution retenue consiste alors en un auto apprentissage des habitudes du conducteur en s'appuyant sur une base de données. La stratégie qui semble la plus adaptée est donc le MPC. Toutefois, l'une des méthodes d'optimisation globale, la DP, sera utilisée comme référence pour évaluer la stratégie mise en place.

Lors de cette phase d'évaluation, le cycle considéré est important puisque son impact est d'ordre 1. Comme il n'existe pas de cycle de référence dans la littérature, le choix qui a été fait est justifié dans un chapitre suivant. Des cycles standards, utilisés pour les essais de normalisation, seront considérés pour avoir un élément de comparaison avec de nombreux autres véhicules. De plus, des cycles routiers réels, relevés grâce à un boîtier d'acquisition de données, seront aussi considérés de manière à stresser l'algorithme mis en place.

En analysant toutes les gestions énergétiques présentées jusque là, il est évident que le




FIGURE 1.52 – Gestion énergétique envisagée pour la suite du mémoire

profil du conducteur a une importance majeure sur les performances de la stratégie et doit être pris en compte. Pour ne pas lui ôter le plaisir de conduire (car il existe déjà un système qui indique au conducteur comment rouler pour économiser du carburant [130]), la stratégie devra s'adapter au style de conduite de l'automobiliste tout en minimisant l'impact énergétique du style adopté. Pour cela, il est nécessaire de déterminer quels sont les différents styles de conduite existants en s'appuyant sur les relevés de paramètres tels que l'accélération, la vitesse ou encore le changement de rapport. Ils seront alors construits à partir d'une étude expérimentale qui sera présentée dans un chapitre suivant.

Au regard de tous les points précédents, la gestion énergétique envisagée est présentée sur la figure 1.52. La contribution qu'apporte ce travail réside dans la prise en compte des habitudes du conducteur, non seulement pour générer le cycle de conduite, mais aussi pour caractériser son type de conduite.

ANALYSE STATISTIQUE DES HABITUDES DE CONDUITE

L'étude bibliographique a permis de dégager deux axes importants pour mettre en place une stratégie de gestion énergétique dite "intelligente" : la prédiction de cycle et le profil conducteur. Dans la stratégie envisagée, la première étape consiste à prédire le trajet qui va être réalisé par le conducteur dès le démarrage du véhicule. La seconde étape consiste à prédire le cycle de vitesse le long du parcours de manière à adapter la gestion énergétique. C'est ce cycle qui déterminera le profil conducteur. Il devra être le plus représentatif possible de la dynamique de conduite de chacun. Mais avant tout, il faut commencer par vérifier que cette notion de "prédiction" est réalisable.

Pour cela, il faut s'intéresser à la mobilité des français. Plusieurs études ont déjà été menées à ce sujet, notamment par l'ADEME, le Ministère du Développement Durable ou encore l'INSEE ([4, 53]). Les résultats sont présentés sur la figures 2.1 et dans la table 2.1. Il se dégage de ces études deux conclusions importantes :

- la distance moyenne journalière des français est inférieure à 80km et ce type de trajet appelé mobilité locale est prépondérante
- la mobilité "contrainte"¹ représente 50% des déplacements

Nous avons la possibilité de mettre une campagne d'essai en place dans le contexte de cette thèse, à la fois pour confirmer la dominance des déplacements quotidiens contraints, et surtout pour constituer une base de données de trajets réels. Cette base expérimentale dans le département de la Nièvre permettra d'évaluer la stratégie mise en place dans le chapitre 3. Dans le cadre de l'étude, un panel représentatif a été élaboré en respectant la méthode des quotas (sexe, âge) (figure 2.2). La population considérée est la population active Nivernaise qui se rend sur son lieu de travail en voiture. Les données sont issues d'une étude de l'INSEE datant de 2008. Au total 40 automobilistes ont été sélectionnés suivant ces critères et leurs trajets ont été enregistrés durant 4 semaines.

1. se rendre sur son lieu de travail et faire ses courses




FIGURE 2.1 – Motivation des déplacements [53]




FIGURE 2.2 – Répartition de la population suivant la méthode des quotas

2.1/ PRÉSENTATION DU MOYEN D'ESSAI ET VALIDATION DES MESURES

Dans la première partie de ce chapitre, le moyen d'essai mis en place pour réaliser l'étude expérimentale est présentée. De plus, la validation des mesures est démontrée en s'appuyant sur un protocole de test détaillé.

2.1.1/ BOÎTIER D'ACQUISITION

Après avoir examiné les solutions existantes dans le commerce (datalogger, tablette...), il a été décidé de mettre au point notre propre moyen d'essai, pour des raisons tant économiques que technique (2.2). En effet la solution retenue doit nous permettre de maîtriser les capteurs et d'adapter notre moyen d'essai à nos exigences. Pour cela, un cahier des charges a été dressé avant de réaliser un prototype. L'une des contraintes principales est l'autonomie énergétique souhaitée pour le boîtier afin d'éviter tout branchement sur les véhicules des participants.

Après le développement du premier prototype, 15 boîtiers d'acquisition de données auto-




FIGURE 2.3 – Photo du premier boîtier prototype réalisé

nomes ont été réalisés (figure 2.3). Chaque boîtier est constitué d'un Arduino Uno, d'un shield GPS, d'un emplacement micro SD et d'une centrale inertielle dont seul l'accéléromètre trois axes est utilisé. Enfin pour enregistrer les données, le dispositif d'acquisition est équipé d'une carte micro SD de 32Go.

Les données relevées au cours de l'étude sont :

- la date et l'heure
- les coordonnées GPS
- la vitesse
- l'accélération suivant les trois axes

Les trois premières seront récupérées grâce au GPS dont seule la trame RMC² est enregistrée. Cette trame est de la forme suivante et l'explication de chaque partie la composant est donnée dans la table 2.3 :

\$GPRMC,162457.800,A,4651.9132,N,00309.7870,E,2.63,274.56,140416,,A*6B

Les acquisitions GPS se font à une fréquence de 10 Hz qui correspond à la fréquence maximale du capteur. La fréquence d'acquisition des valeurs de l'accéléromètre fera quand à elle, l'objet d'une étude et sera traitée dans la section 2.1.2. Par la suite, la validation des mesures sera présentée.

Durant la phase de test du prototype, un problème majeur est survenue concernant l'alimentation. En effet, après avoir dimensionné la capacité nécessaire de la batterie pour tenir 1 mois, le premier choix s'est porté sur une batterie nomade (souvent utilisée pour la recharge des téléphones portables). Afin d'éviter une consommation inutile lors des phases où le véhicule est arrêté, le GPS est coupé et l'accéléromètre et l'Arduino sont

2. trame du protocole NMEA (National Marine & Electronics Association)

mis en sommeil. Le réveil de l'ensemble des capteur est réalisé par la détection d'une accélération. Ce système, indispensable pour avoir un moyen d'acquisition autonome sur 1 mois, s'est trouvé être incompatible avec une batterie nomade. En effet, cette dernière est faite de telle manière qu'elle se coupe en dessous d'un certain seuil d'intensité (i.e. quand l'appareil est sensé être chargé). Dans notre cas, elle se coupe lorsque le moyen d'acquisition passe en mode basse consommation, empêchant son redémarrage. Après avoir étudié la possibilité de double alimentation (USB pour batterie nomade et sur le 5V pour des piles) et plusieurs types de piles, l'autonomie souhaitée est finalement assurée par un pack batterie fabriqué en assemblant 18 piles de type 18650 (capacité totale de 26Ah pour une tension de 7.4V).

2.1.2/ ÉTUDE DE LA FRÉQUENCE D'ACQUISITION DE L'ACCÉLÉROMÈTRE

De manière à déterminer la fréquence d'acquisition minimale à utiliser pour l'accéléromètre, plusieurs boîtiers ont été utilisés simultanément, chacun à une fréquence différente. Les fréquences choisies pour l'étude sont : 500 Hz, 250 Hz, 100 Hz, 50 Hz et 10Hz. Le GPS quant à lui fonctionne à la fréquence de 10 Hz dans chacun des cas. Dans un premier temps, les résultats seront analysés dans le domaine fréquentiel pour observer si une fréquence est privilégiée dans la dynamique de conduite auquel cas la fréquence d'acquisition minimale devra être supérieure, puis une analyse dans le domaine temporel sera présentée.

Analyse fréquentielle

Pour analyser les données dans le domaine fréquentielle, une Transformée de Fourier Rapide (Fast Fourier Transform - FFT) a été appliquée au signal brut. La figure 2.4 présente les résultats pour l'ensemble des fréquences utilisées. Pour faciliter l'analyse, les données sont présentées dans un repère logarithmique. On remarque qu'il n'existe aucune fréquence préférentielle dans la dynamique de conduite puisqu'il ne se dégage aucun pic en amplitude. Le choix de la fréquence d'acquisition sera donc indépendant de ce critère, et les valeurs relevées ne seront pas perturbées par une éventuelle résonance du moyen de mesure.

Analyse temporelle

Les résultats dans le domaine temporel sont présentés sur la figure 2.5. On observe une bonne corrélation des résultats entre les différents signaux. Si l'on zoom (figure 2.5b) dans une zone où de fortes accélérations et décélérations sont représentées, on peut voir qu'une fréquence d'acquisition de 10 Hz semble suffisante pour capter les tendances principales du signal. Cette impression est confirmée par la figure 2.6 qui représente l'histogramme des accélérations pour chaque fréquence, et par les travaux de E. Ericsson [38]. Le décalage temporel entre les différentes courbes est dû au filtre passe bas de l'accéléromètre dont la bande passante varie suivant la fréquence, ce qui induit un retard.

Pour déterminer numériquement les différences entre les histogrammes, un calcul de corrélation a été effectué pour chaque fréquence d'acquisition, en prenant les valeurs acquises à 500 Hz comme référence. Ce calcul retourne un coefficient de corrélation, noté R , qui caractérise la dépendance linéaire entre deux séries aléatoires et la valeur p , notée P , qui détermine la probabilité d'avoir la même valeur si le rapport entre les




FIGURE 2.4 – Transformée de Fourier des signaux acquis à différentes fréquences

deux séries est du au hasard. La valeur de R pour deux séries A et B est obtenue avec l'équation 2.1.


$$R = \frac{1}{N-1} \sum \left(\frac{A_i - \mu_A}{\sigma_B} \right) \left(\frac{B_i - \mu_B}{\sigma_B} \right) \quad (2.1)$$

avec μ la moyenne et σ l'écart type de la série considérée.


Dans notre étude, on obtient les coefficients de corrélation qui sont présentés dans la table 2.4. Ceux ci sont relativement élevés puisqu'ils sont tous supérieurs à 90%. On peut donc en déduire qu'une fréquence d'acquisition de 10 Hz est suffisante pour capter la dynamique des conducteurs. Il n'y a pas plus d'informations captées au delà mais seulement du bruit. L'étude a été poursuivie en moyennant donc à 10 Hz toutes les acquisitions dont la fréquence initiale est supérieur à 10 Hz (50, 100, 250 et 500 Hz). Les résultats démontrent qu'il est intéressant de prendre une fréquence plus importante puis de la moyenner, pour lisser les valeurs et être certain de capter toutes les variations. Une fréquence de 100 Hz a donc été choisie pour la suite.

2.1.3/ RÉPÉTABILITÉ ET REPRODUCTIBILITÉ DES MESURES

Si l'on cherche à valider expérimentalement le moyen d'essai, il faut tout d'abord s'intéresser à la fidélité des mesures. Pour cela, la référence à laquelle les enregistrement



(a) Evolution temporelle de l'accélération



(b) Zoom sur la courbe temporelle

FIGURE 2.5 – Influence de la fréquence d'acquisition

seront comparés est un GPS que possède le laboratoire DRIVE, et dont la précision est centimétrique. Une fois la précision de mesure validée, il est important de démontrer la reproductibilité et la répétabilité des mesures. La première consiste à comparer les résultats obtenus par plusieurs boîtiers sur un même trajet alors que la seconde consiste à comparer les résultats d'un même boîtier sur un même trajet réalisé plusieurs fois. Pour la majorité des données analysées, la notion de répétabilité n'est pas vérifiable en conditions réelles. En effet, en raison d'un trafic plus ou moins dense, d'un feu de signalisation favorable ou non, etc... le cycle de conduite sera différent et il sera donc difficile de comparer la vitesse et l'accélération d'un trajet à l'autre. En statique, le coefficient de variation est utilisée pour caractériser la reproductibilité. Ce coefficient, c_v , représente le rapport de l'écart type σ sur la moyenne μ (équation 2.2). Les équations qui servent à calculer ces grandeurs sont présentées dans les équations 2.3 et 2.4. Cependant il est compliqué d'utiliser le coefficient de variation dans notre cas, car les valeurs (notamment celles de l'accéléromètre) sont proches de 0. Ainsi avec une moyenne proche de 0, quelque soit la valeur de l'écart type, le coefficient de variation prendra des valeurs trop importantes. La validation s'appuiera donc sur le coefficient de corrélation des matrices de vitesse.




FIGURE 2.6 – Représentation du temps passé par intervalle d'accélération (intervalle par pas de 0.01ms^2)

$$c_v = \frac{\sigma}{\mu} \quad (2.2)$$

$$\sigma = \frac{\sigma}{\mu} \quad (2.3)$$

$$\mu = \frac{1}{n} \sum x_i \quad (2.4)$$

2.1.3.1/ ACCÉLÉROMÈTRE

L'étude de reproductibilité des mesures de l'accéléromètre a été effectuée sur un même trajet avec 7 boîtiers à une fréquence de 100 Hz. Seules les courbes représentant l'accélération longitudinale sont représentées sur la figure 2.7, mais les résultats sont transposables suivant les deux autres axes du repère. Les boîtiers sont numérotés de 01 à 15 et ils sont notés B## dans la suite du chapitre. De même que précédemment, on remarque une bonne corrélation des résultats entre les boîtiers, tant visuellement (figure 2.7) que numériquement (tableau 2.5). Avec un coefficient de corrélation minimum supérieur à 90%, la reproductibilité des résultats est assurée. Ces mesures ont été réalisées plusieurs fois et l'on retrouve les mêmes coefficients de corrélation.

2.1.3.2/ GPS

Concernant le GPS, deux grandeurs seront étudiées à savoir les coordonnées et la vitesse. Pour chacune d'elles, les données seront comparées à un étalon qui est un GPS de type RTK. Ce type de GPS fonctionne avec une correction différentielle, émise par




FIGURE 2.7 – Reproductibilité des résultats de l'accéléromètre suivant l'axe longitudinal

une station fixe installée à un endroit dont on connaît les coordonnées exactes avec un signal radio basse fréquence (figure 2.8). Ce système permet d'avoir une précision centimétrique sur la position dans un rayon de l'ordre de 10km. Le GPS de type RTK a été utilisé à une fréquence de 1 Hz contrairement aux boîtiers GPS qui étaient à 10 Hz. Puis la reproductibilité des deux grandeurs ainsi que la répétabilité des coordonnées GPS seront présentées. Pour valider la fiabilité des données, les résultats seront comparés aux données du constructeur du GPS. La précision indiquée dans ce document est de 3m pour la position et de 0.1m/s pour la vitesse.

Coordonnées

Plusieurs études ont été menées pour valider l'acquisition des coordonnées GPS. La première consiste à déterminer l'écart de mesure entre le boîtier d'acquisition mis au point et le GPS de type RTK. Pour cela 7 boîtiers ont été placés à côté du GPS de référence et les résultats sont présentés sur la figure 2.9. La seconde étude a pour but de déterminer la répétabilité (figure 2.10a) et la reproductibilité des résultats (figure 2.10b). Les coordonnées GPS sont la seule grandeur dont la répétabilité peut être étudiée. En effet, quelque soit les conditions de circulation, le parcours réalisé ne change pas.

La comparaison des mesures issues des GPS des boîtiers avec les mesures du GPS de type RTK est présentée sur la figure 2.9. On remarque que les courbes sont relativement proches. L'écart maximum le long du trajet est quand à lui présenté dans la table 2.6. Les chiffres valident la précision du GPS des boîtiers conçus puisque l'écart est inférieur à 3m. D'autant plus que les tests ont été réalisés dans des conditions peu idéales pour la réception : en ville et par temps couvert (voir légèrement pluvieux).

Au vue des écarts indiqués pour le graphe précédent, on peut en déduire que l'écart est une fois encore inférieur aux 3m spécifiés par le constructeur. La fidélité et la répétabilité de la mesure sont donc assurées. La figure 2.10b apportent les mêmes conclusions concernant la reproductibilité de la mesure.




FIGURE 2.8 – Principe de fonctionnement d'un GPS de type RTK

Vitesse

De même que pour les coordonnées GPS, la précision de la mesure de vitesse des boîtiers d'acquisition par rapport au GPS de type RTK est présentée sur la figure 2.11 et reporté dans la table 2.7. On notera qu'il n'existe aucun lien entre les écarts en vitesse et les écarts de position vus précédemment. Le boîtier B11 est celui dont l'écart est le plus important. Il est donc intéressant d'observer la distribution d'écart de vitesse entre celui-ci et le GPS de type RTK. Les résultats sont présentés sur la figure 2.12. On observe que plus de 80% des mesures ont un écart ne dépassant pas 5km/h (en valeur absolue).

Concernant la reproductibilité des mesures, la figure 2.13 et 2.14 démontrent qu'elle est bonne. En effet, si l'on s'intéresse à la figure 2.14 qui représente la dispersion autour de la moyenne, on s'aperçoit que celle-ci est faible. Cela permet donc de valider la reproductibilité de la mesure de vitesse issue du GPS.

Afin d'estimer si l'incertitude de mesure sur la vitesse sera préjudiciable pour la suite de l'étude, l'impact sur l'énergie a été calculé. Pour cela, la puissance a été calculée en utilisant le principe fondamentale de la dynamique et en considérant les données (masse, aire frontale...) du véhicule utilisé pour la phase de validation. Les résultats sont présentés dans la table 2.8. On constate que l'incertitude de mesure de la vitesse engendre un écart inférieur à 5% sur le calcul de l'énergie. La mesure de vitesse peut donc être considérée suffisamment précise pour notre étude.

2.1.4/ CONCLUSION SUR LE MOYEN D'ESSAI

Le système d'acquisition de données complètement autonome qui a été mis en place répond parfaitement au besoin formulé. De plus après avoir réalisé différents test tels que la répétabilité et la reproductibilité, et après avoir chiffré l'écart induit par l'incertitude de mesure sur les différentes grandeurs caractéristiques, le moyen d'essai est considéré comme valide.






FIGURE 2.9 – Comparaison des coordonnées GPS entre le système d'acquisition et le module RTK



(a) Répétabilité



(b) Reproductibilité

FIGURE 2.10 – Validation des mesures de coordonnées GPS




FIGURE 2.11 – Comparaison des profils de vitesse issus du GPS entre le système d'acquisition et le module RTK

TABLE 2.1 – Déplacements quotidiens des français

Type de zonage urbain	Temps passé (en minutes)	Distance moyenne par- courue (en km)	Vitesse moyenne (en km/h)
Espace à dominante rurale	49	29	35
Commune polarisées d'aires urbaines < 100 000 habitants	47	28	35
Pôles urbains d'aires urbaines < 100 000 habitants	53	24	28
Communes multipolarisées	53	33	37
Communes polarisées d'aires urbaines > 100 000 habitants (hors Paris)	55	32	35
Banlieues de pôles urbains d'aires urbaines > 100 000 habitants (hors Paris)	54	24	26
Centres de pôles urbains d'aires urbaines > 100 000 habitants (hors Paris)	55	17	19
Communes polarisées de l'aire urbaine de Paris	67	39	35
Banlieue parisienne	72	22	19
Paris	75	15	12

TABLE 2.2 – Tableau comparatif des solutions existantes dans le commerce par rapport au moyen d'essai mis en place

Critères	datalogger	tablette	boîtier d'acquisition
Capteur de position	GPS intégré	GPS intégré	GPS MT3339
Précision du capteur	NC	5m	3m
Capteur de vitesse	GPS intégré	GPS intégré	GPS MT3339
Fréquence	10 Hz	NC	10 Hz
Capteur d'accélération	aucun	accéléromètre interne	centrale inertielle MPU9250
Consommation électrique	0.5A	0.56A	0.07A
Système d'alimentation	batterie	batterie	externe
Autonomie	24h	13h	2 semaines
Taille de stockage	8Go	32Go	carte SD 32Go
Prix en euro	150	200	170

TABLE 2.3 – Détails de la trame GPS

Bout de trame	Explications
\$GPRMC	type de trame
162457.800	heure UTC exprimée en hhmmss.sss : 16h 24m 57s 800ms
A	état A=données valides, V=données invalides
4651.9132	Latitude exprimée en ddmm.mmmm : $46^{\circ}51.9132' = 46^{\circ}31'8,875''$
N	indicateur de latitude N=nord, S=sud
00309.7870	Longitude exprimée en dddmm.mmmm : $003^{\circ}09.7870' = 3^{\circ}5'52,331''$
E	indicateur de longitude E=est, W=ouest
2.63	vitesse sur le fond en noeuds ($2,63 \text{ kn} = 3,03 \text{ mph} = 4,87 \text{ km/h}$)
274.56	route sur le fond en degrés
140416	date exprimée en jjmmaa : 14 Avril 2016
,	déclinaison magnétique en degrés (souvent vide pour un GPS)
,	sens de la déclinaison E=est, W=ouest (souvent vide pour un GPS)
A	mode de positionnement A=autonome, D=DGPS, E=DR
*6B	somme de contrôle de parité au format hexadécimal

TABLE 2.4 – Coefficient de corrélation avec l'histogramme des données à 500 Hz

	10 Hz	50 Hz	100 Hz	250 Hz	500 Hz
<i>R</i>	0.977	0.98	0.963	0.937	1
<i>R</i> pour valeur moyennée à 10 Hz	0.977	0.941	0.947	0.886	0.958

TABLE 2.5 – Coefficient de corrélation *R* des histogrammes à 100 Hz moyennés sur 10 Hz

	B06	B08	B09	B11	B12	B13
<i>R</i>	0.976	0.925	0.950	0.997	0.953	0.951

TABLE 2.6 – Ecart relatif de positionnement entre les boîtiers d'acquisition et le GPS de type RTK

	B02	B03	B08	B09	B10	B11	B12	écart moyen
écart relatif								
maximum (en m)	0.19	0.15	0.20	0.19	0.16	0.53	0.15	0.22

TABLE 2.7 – Ecart relatif de vitesse entre les boîtiers d'acquisition et le GPS de type RTK

	B02	B03	B08	B09	B10	B11	B12	écart moyen
écart relatif								
maximum (en km/h)	10.3	15.6	9.2	14.5	11.2	24.0	14.5	14.2




FIGURE 2.12 – Répartition de l'écart de vitesse entre le boîtier B11 et le GPS RTK




FIGURE 2.13 – Reproductibilité des relevés de vitesse issus du GPS

TABLE 2.8 – Ecart relatif d'énergie entre les boîtiers d'acquisition et le GPS de type RTK

	B02	B03	B08	B09	B10	B11	B12	RTK
Energie totale (kJ)	233.7	224.9	223.3	221.6	225.5	238.6	229.3	233
Ecart relatif (%)	-0.3	3.5	4.2	4.9	3.2	-2.4	1.6	




FIGURE 2.14 – Dispersion des mesures de vitesse autour de la moyenne

2.2/ ANALYSE DES TRAJETS

La campagne d'essai a permis de récolter une base de données de plus de 13 000 km répartis sur 1 625 trajets. L'analyse de ces données a deux objectifs : étudier la prédictibilité des trajets et analyser la dynamique de conduite des automobilistes. Chacun de ces points s'appuie sur une méthode d'inter-corrélation normalisée décrite dans la section suivante.

2.2.1/ MÉTHODE D'INTER-CORRÉLATION NORMALISÉE

La corrélation est une mesure de la similitude de forme et de position entre deux signaux. Pour illustrer cette définition, un exemple est présenté dans la figure 2.15. L'image B est translaturée et à chaque position de B en X et en Y un nouveau coefficient de corrélation est calculé. Le résultat final est une matrice dont la taille correspond à celle des images d'origine et qui possède un pic de corrélation qui correspond à la translation de B pour laquelle les deux disques se superposent parfaitement. La position du pic par rapport à l'origine (centre de la carte) correspond au vecteur de translation à appliquer pour recentrer l'image B par rapport à l'image A ($x+15, y-15$).




FIGURE 2.15 – Exemple d'inter-corrélation (issu de [122])

Mathématiquement, la fonction d'inter-corrélation normalisée est exprimée par l'équation 2.5.

$$\gamma(u, v) = \frac{\sum x, y [f(x, y) - \bar{f}_{u,v}] [t(x - u, y - v) - \bar{t}]}{\left\{ \sum x, y [f(x, y) - \bar{f}_{u,v}]^2 \sum x, y [t(x - u, y - v) - \bar{t}]^2 \right\}^{0.5}} \quad (2.5)$$

avec f l'image, t le modèle et $\bar{f}_{u,v}$ la moyenne de $f(x, y)$ dans la région du modèle.

2.2.2/ ANALYSE STATISTIQUE

Depuis plusieurs années, certaines organisations s'intéressent à la mobilité des français et ont ainsi pu établir une analyse de celle-ci ([4, 53]). Le but de ce paragraphe est

de comparer nos résultats à d'autres études pour vérifier la représentativité de notre campagne d'essai. Les résultats du Ministère du Développement Durable présentés dans la table 2.9 sont pris pour un milieu rural, ce qui correspond à la situation de la Nièvre.

TABLE 2.9 – Comparaison entre les résultats de l'étude expérimentale et l'étude du Ministère du Développement Durable (données journalières)

	Données de la littérature	Données de l'étude
nombre de trajets	3.15	3.2
distance moyenne (km)	29	24.6 ± 4.1
vitesse moyenne (km/h)	35	52.2 ± 10.6
temps moyen (min)	49 (17.9 pour 1 trajets)	28.7 ± 5.5

On constate que le nombre de trajets journaliers est sensiblement équivalent. Les autres grandeurs diffèrent mais restent cohérentes puisque pour une distance moyenne équivalente, le temps passé est inférieur mais la vitesse supérieure. Ceci s'explique par la topographie de la région et notamment la présence d'une autoroute empruntée par plus de la moitié des conducteurs de la base de données (61.5%). La distribution de la distance journalière parcourue par les automobilistes de l'étude est présentée en figure 2.16. On observe un pic autour de 25km qui représente 25% de la population étudiée.

L'étude menée est donc représentative de ce qui a pu être observé au niveau national pour les milieux ruraux, ce qui permettra de valoriser les résultats de notre étude au delà des frontières de la Nièvre.

Afin de dimensionner le groupe moto-propulseur hybride, il est intéressant de s'intéresser aux besoins d'énergie des trajets. Pour cela, une étude du besoin en puissance des automobilistes testés a été réalisée. En fixant un poids moyen du véhicule, il est possible de remonter de la vitesse et l'accélération à l'énergie nécessaire et à l'énergie récupérable 2.10.

TABLE 2.10 – Energie nécessaire et énergie récupérable

	Energie nécessaire moyenne (écart type) en MJ	Energie récupérable moyenne (écart type) en MJ
Trajet domicile/travail	12.3 (1.3)	1.02 (0.05)
autres trajets	23.2 (15.1)	2.14 (1.92)

On observe que l'énergie nécessaire au quotidien est inférieur à l'énergie disponible dans les batteries actuelles des véhicules électriques. Cela conforte les chiffres de la mobilité issus de l'étude expérimentale qui démontrent qu'une voiture électrique répond parfaitement au besoin de déplacement quotidien. Cependant, dans le cas d'un véhicule hybride, le trajet aller/retour domicile-travail peut pousser la batterie dans ses retranchements. Il est donc nécessaire d'avoir une stratégie qui optimise l'utilisation de l'énergie et notamment les phases de freinage. D'autant, qu'il est possible, dans notre étude, de récupérer près de 10% de l'énergie utilisée lors des phases de freinage. L'écart type observé sur les trajets hors domicile-travail est dû à la différence de longueur des trajets non contraints (de 1.5km à plus de 100 km).




FIGURE 2.16 – Répartition de la distance journalière parcourue par les automobilistes de l'étude

2.2.3/ PRÉDICTIBILITÉ DES TRAJETS

La prédictibilité d'un trajet, ρ , est définie comme étant le pourcentage de chance de réaliser ce trajet connaissant les coordonnées de départ. Cette donnée servira de base à la stratégie mise en place dans le chapitre 3.

La prédictibilité est définie suivant l'équation 2.6 et sa méthode de calcul est représentée schématiquement sur la figure 2.17. γ représente le résultat de l'inter-corrélation entre les trajets.

$$\rho = \frac{\gamma(> 90)}{\gamma(\neq 0)} \quad (2.6)$$




FIGURE 2.17 – Déroulement de la procédure de calcul de prédictibilité

Pour l'ensemble des conducteurs, la prédictibilité a été étudiée dans un premier temps de manière globale i.e. sans distinction de jour. Dans un second temps, les trajets ont été séparés en deux catégories : les trajets de semaine et les trajets de weekend. On observe alors une différence importante de prédictibilité directement liée à la mobilité contrainte de la semaine (figure 2.18). En effet plus de 75% des trajets ont au moins 5 occurrences en semaine alors qu'en weekend 40% des trajets sont uniques. Il existe deux justifications possibles à cela. Premièrement, la base de données en weekend est nettement moins importante et deuxièmement, les trajets du week-end sont rarement dus à une mobilité contrainte mais davantage une mobilité pour les loisirs.






FIGURE 2.18 – Répétition des trajets

La figure 2.19 présente les trajets des conducteurs dont la prédictibilité est aux extrêmes. Si l'on se penche sur les trajets du conducteur du haut, il est fort probable que ce soit une voiture secondaire puisque seulement 2 trajets ont été enregistrés en weekend. Elle sert donc essentiellement à se rendre sur le lieu de travail ce qui justifie la très haute prédictibilité. Ce genre d'automobiliste représente la cible idéale pour la stratégie mise en place dans le chapitre 3. Quand au conducteur du bas, il réalise de nombreux trajets en centre ville et adapte probablement ces trajets aux conditions de circulation (bouchons, travaux). Ce sera probablement la personne qui obtiendra les moins bons résultats d'optimisation sur la stratégie de gestion énergétique, du fait de la faible prédictibilité de ses trajets. Les résultats de la stratégie pour ces deux personnes seront présentés spécifiquement dans le chapitre 3.

En s'intéressant aux coordonnées GPS, on observe que les coordonnées de départ peuvent varier d'un cycle à l'autre pour un parcours identique. Cela est dû au temps de géolocalisation du GPS lorsqu'il sort du mode utilisation basse consommation. Cela peut prendre jusqu'à 3 minutes d'après les données fabricants, mais n'a jamais excédé les 90s dans notre étude. Le graphique 2.20 présente la position des points de départs et la position des points d'arrivées pour l'intégralité des trajets d'une personne. On distingue une meilleure précision concernant les fins de trajets. L'écart est uniquement dû à la variation des places de parking comme étudié dans les travaux de G. Pasaoglu et al. [85]. Pour chaque automobiliste et sur chaque cycle identique, l'écart moyen entre les coordonnées



(a) Predictibilité maximale



(b) Predictibilité minimale

FIGURE 2.19 – Totalité des trajets pour les automobilistes ayant les prédictibilités extrêmes

de départ et d'arrivée a été calculé. La table 2.11 présente la variation moyenne, minimale et maximale, ainsi que la différence entre en ville et hors ville. La valeur maximale pour la position de départ a été enregistrée en ville un jour de forte pluie, alors que pour la position d'arrivée, semble du à l'utilisation d'un parking plus éloigné que d'habitude pour l'automobiliste. Concernant les écarts de position minimaux, ils sont sensiblement identique en agglomération ou en dehors, étant donné que certaines places de parking privés sont attribués en ville.

TABLE 2.11 – Variabilité des coordonnées de départ et d'arrivée pour un même trajet

	Global			En ville		Hors ville	
	moyenne	maxi	mini	maxi	mini	maxi	mini
écart coordonnées de départ (m)	100	312	2.7	312	4.9	256	2.7
écart coordonnées d'arrivé (m)	18	151	1.5	151	2	50	1.5




FIGURE 2.20 – Position des points de départ et des points d'arrivée de l'ensemble des trajets d'un automobiliste

2.3/ PRÉDICTION DE CYCLE

L'analyse précédente a permis de mettre en évidence la capacité de prédire le trajet d'une personne avec un fort taux de réussite en semaine. Cependant les coordonnées GPS ne sont pas des données utiles pour la stratégie de gestion énergétique au contraire du cycle de vitesse qui traduit le besoin énergétique du trajet. Pour prédire ce cycle, plusieurs approches ont été envisagées. La première, assez basique, consiste à considérer la moyenne des cycles enregistrés (figure 2.21). Cependant, cette méthode ne convient pas puisqu'elle lisse une partie de la dynamique de conduite.

La deuxième solution envisagée, s'inspire des chaînes de Markov et a été utilisée pour tenter d'ajouter une composante dynamique au cycle créé. La troisième solution s'appuie sur la méthode de corrélation croisée vu précédemment pour définir un cycle représentatif. Ces deux approches retenues sont présentées dans la suite du chapitre.

2.3.1/ CHAÎNE DE MARKOV

Les chaînes de Markov sont des processus stochastiques qui prédisent l'état d'une variable au temps $t+1$ en fonction uniquement de son état au temps t . La probabilité de transition de l'état i à l'état j peut être représenté comme sur la figure 2.22. Les flèches représentent les probabilités de transition d'un état à un autre. Pour des systèmes dont les états possibles sont multiples, une matrice de transition est déterminée préalablement et se présente telle que sur la figure 2.23. Pour plus de détails sur la théorie des chaînes de Markov, le lecteur pourra se référer aux travaux de L.R. Rabiner [92].

Dans le cadre de notre étude, les relevés de l'accéléromètre ont permis d'établir une cartographie des accélérations en fonction de la vitesse (figure 2.24). Cette cartographie représente donc les probabilités de passage d'un état à un autre.

Il a été tenté de créer un cycle artificiel mais réaliste, en s'appuyant sur ces données. Pour cela on procède à un tirage aléatoire des valeurs dont les probabilité d'être tirées




FIGURE 2.21 – Représentation de la moyenne

correspondent aux valeurs de la cartographie. Cependant, une contrainte est ajoutée pour borner la vitesse suivante afin qu'elle ne dépasse pas la moyenne plus 3 fois l'écart type. Celle-ci a été ajoutée pour ne pas obtenir de cycles trop déviants de ce qui a pu être enregistré dans l'historique. L'algorithme utilisé est identique à celui de la figure 2.25 issu de [110].

Les résultats obtenus sont présentés sur la figure 2.26. On constate que le processus de Markov a simplement ajouté de la dynamique autour de la moyenne mais n'a pas créé un profil aléatoire s'approchant d'un profil réel enregistré. De plus on constate que la dynamique générée est plus importante que la dynamique conducteur enregistrée. C'est pour ces 2 raisons que cette méthode a été abandonnée et que la méthode explicitée au paragraphe suivant a été privilégiée.




FIGURE 2.22 – Exemple élémentaire de chaîne de Markov à 2 états




FIGURE 2.23 – Matrice de transition d'une chaîne de Markov [110]




FIGURE 2.24 – Exemple de trajet et de cartographie associée






FIGURE 2.25 – Principe de l'algorithme d'un processus de Markov [110]



(a) Cycle intégral



(b) Zoom sur une portion du cycle

FIGURE 2.26 – Comparaison de profil de vitesse entre profil généré, profil moyen et profil réel

2.3.2/ DÉFINITION DU CYCLE LE PLUS REPRÉSENTATIF

L'idée de base de la méthode qui est présentée dans cette section est de considérer qu'un trajet déjà réalisé est représentatif de la dynamique de conduite de l'utilisateur. Nonobstant il existe des possibilités de cycles de vitesse particuliers dues à des conditions de trafic exceptionnelles. La problématique est donc d'identifier parmi les cycles enregistrés celui qui est le plus représentatif. Une fois de plus, la méthode d'inter-corrélation normalisée permet de réaliser ce travail. En effet, en comparant l'ensemble des cycles de vitesse pour des parcours identiques il est possible de déterminer lequel a le plus de ressemblance avec l'ensemble des autres. Cela consiste à sommer en ligne les résultats de l'inter corrélacion des différents cycles, comme présenté dans la table 2.12 étant donné que la matrice est symétrique. Dans l'exemple présenté, le trajet 3 est considéré comme le plus représentatif et servira donc de référence pour déterminer la stratégie de gestion énergétique.

TABLE 2.12 – Exemple d'inter-corrélation normalisée sur 3 cycles de vitesse représentant le même trajet

	trajet 1	trajet 2	trajet 3	Somme
trajet 1	1	0.85	0.9	2.75
trajet 2	0.85	1	0.95	2.80
trajet 3	0.9	0.95	1	2.85

Afin d'expliciter la méthodologie, un scénario simplifié est présenté dans la table 2.13 et explicité dans ce paragraphe. Prenons le cas d'une personne utilisant son véhicule quasi exclusivement pour aller travailler. Le trajet n°1 représente le trajet domicile/travail. Il a été réalisé 6 fois en semaine. Et sa prédictibilité est à 100% puisqu'au démarrage du domicile, c'est le seul parcours réalisé par l'automobiliste en semaine. Le cycle le plus représentatif déterminé par la méthode d'inter-corrélation est le 6. Les trajets n°2 et 3 représentent le retour du travail. Dans le premier cas, le conducteur rentre directement chez lui, dans le second cas il s'arrête faire ses courses. Au départ du travail, la table indique qu'il y a 60% de chance qu'il rentre chez lui contre 40% de chance qu'il passe faire des courses. Les trajets 4 et 5 sont des trajets de weekend au départ du domicile pour des lieux différents, les probabilités sont donc de 50%. On notera que les cycles 5 et 11 qui sont les retours des trajets du weekend, ainsi que les cycles 3 et 10 qui sont les trajets courses/domicile n'ont pas été intégrés pour simplifier la table. Jusqu'à présent un bilan des trajets déjà effectués a été présenté, le nouveau trajet effectué (n°18) est quand à lui ajouté en rouge. A la fin du trajet le calcul de prédictibilité est mis à jour ainsi que le cycle le plus représentatif. C'est ainsi qu'est mis en place l'auto apprentissage des trajets et des habitudes de conduite par la voiture.

TABLE 2.13 – Exemple de calcul de probabilité

N° trajet	Cycles réels	Cycle représentatif	Semaine/Weekend	Predictibilite
1	1,6,8,13,15,17	6	S	100%
2	7,14,16 ,18	7 → 18	S	60% (3/5) → 67% (4/6)
3	2,9	2	S	40% (2/5) → 33% (2/6)
4	4	4	W	50%
5	11	11	W	50%

Afin de réduire la taille de la base de données à stocker, le choix a été fait de ne garder en mémoire que 10 cycles pour chaque trajet différents. A l'achat de la voiture, la base de données est vierge. Pour chaque trajet différent, les cycles de vitesse sont enregistrés et stockés jusqu'à atteindre la limite fixée à 10. A la fin du 11^{ème} trajet, la méthode d'inter-corrélation normalisée détermine le cycle le plus représentatif pour le trajet, ainsi que le cycle le moins représentatif qui est alors supprimé de la base de données.

L'une des limitations possible à ce choix est de ne pas tenir compte d'un changement de style de conduite de l'automobiliste, par exemple dû au passage à l'éco-conduite. En effet en cas de changement assez brutal, le nouveau cycle sera écarté à chaque fois, ce qui ne lui laissera pas la possibilité d'être enregistré et comparé aux cycles suivant. De plus, l'existence possible d'une conduite calendaire voir même pendulaire, notamment aux abords des grandes villes, n'est pas prise en compte ce qui peut affaiblir la prédiction du cycle. Cependant ce choix a été fait de manière délibérée afin de limiter la taille de la base de données nécessaire à une optimisation jugée acceptable.

2.4/ CONCLUSION

Dans le but de caractériser le profil des conducteurs, un moyen d'essai a été mis au point. Il permettra de déterminer dans quelle mesure la prédiction de cycle est envisageable. Pour s'assurer du bon comportement des capteurs, plusieurs études ont été menées. Elles concernent les variables enregistrées qui sont la vitesse, les coordonnées GPS et l'accélération. L'étude de ces données a permis de valider leur reproductibilité ainsi que la précision des données GPS. De ce fait les données issues de l'étude expérimentale seront considérées comme fiables.

En s'appuyant sur la base de donnée constituée grâce à l'étude expérimentale, la grande prédictibilité des trajets en semaine a pu être démontrée. Cela valide la faisabilité de notre stratégie basée sur la prédiction de cycle de vitesse. Concernant les trajets en week-end, ceux-ci sont plus aléatoires ce qui détériorera probablement l'efficacité de l'optimisation mise en place. Toutefois il est envisageable, dès lors que les probabilités sont nulles (nouveau trajet), de demander à l'automobiliste de renseigner sa destination directement sur le GPS, mais cela dépasse le cadre de la thèse.

Les prédictibilités générées par cette étude serviront de paramètre d'entrée à la stratégie dans le chapitre suivant. Elles sont stockées dans une matrice qui évolue au fur et à mesure des trajets réalisés. Une amélioration future pour la prédiction de trajets consisterait à étudier l'influence d'une prédictibilité journalière voir horaire. Cependant cela reviendrait à augmenter fortement la taille des données enregistrées.

MODÉLISATION DU VÉHICULE

3.1/ INTRODUCTION

La principale entrave au développement des véhicules électriques reste le "Range Anxiety" ([15, 57, 134]). De ce point de vue, l'une des solutions consiste à concevoir des véhicules avec un moteur thermique d'appoint pour prolonger leur autonomie : les EVRE (Electric Vehicle with Range Extender). C'est le choix fait dans cette étude. Le véhicule considéré ainsi que sa stratégie initiale sont présentés dans une première partie.

D'un point de vue numérique, il est nécessaire de créer un modèle le plus représentatif possible du véhicule. Les trois grandes familles de modèles existantes sont : statique, quasi-statique ou dynamique. Comme spécifié dans la partie 2.1, le modèle dynamique tient compte des limites physiques de chaque composant du modèle, ce qui permet d'obtenir une commande réalisable. Il est le plus complet et la stratégie en temps réel sera donc implémentée et validée en considérant un modèle de ce type. Il existe différentes approches pour créer un modèle dynamique dont les principales sont la Représentation Énergétique Macroscopique (REM) et le bond graph. La REM a été choisie car c'est une méthode ayant déjà été utilisée à de multiples reprises avec succès ([7, 27, 63]) pour la modélisation des véhicules hybrides. Elle est présentée en détail en deuxième partie de ce chapitre.

Néanmoins, un modèle quasi-statique est utilisé pour effectuer la programmation dynamique (DP - Dynamic Programming). En effet, cette dernière étant coûteuse en ressources informatiques, le modèle est simplifié pour obtenir des résultats rapidement.

Une validation du modèle REM basée sur la comparaison avec des valeurs relevées expérimentalement sur le circuit de Magny-Cours est présentée en troisième partie. Puis une comparaison entre les deux modèles (quasi-statique et dynamique) est dressée en quatrième partie.

La cinquième partie est consacrée à l'optimisation énergétique du véhicule et présente la stratégie mise en place, se basant sur les conclusions de la prédiction de cycle, faites dans le chapitre 2.



FIGURE 3.1 – NOAO

3.2/ PRÉSENTATION DE LA NOAO ET DE SA STRATÉGIE DE COMMANDE

Le Pôle de Performance de Nevers Magny-Cours (PPNMC) a développé en 2012 la première voiture de pilotage électrique avec prolongateur d'autonomie [1]. Ce véhicule baptisé NOAO (de l'anglais "know-how") concentre tout le savoir faire technologique mis en commun par les entreprises du PPNMC pour concevoir de A à Z un projet collaboratif d'excellence (figure 3.1).

Les caractéristiques techniques de chaque élément de la chaîne de traction sont présentées dans la table 3.1.

La stratégie de gestion énergétique de la Noao est basée sur des règles. Elle a été choisie pour sa simplicité et sa large utilisation dans les démonstrateurs. La stratégie de contrôle initialement intégrée à la NOAO est constituée de trois sous systèmes :

- Le RE_Control qui détermine le mode de fonctionnement du Range Extender (course, entraînement...). De ce choix découle la consigne de puissance ainsi que le seuil de déclenchement du Range Extender. La décision est prise en s'appuyant sur une quinzaine de paramètres dont certains sont classiques (la vitesse, la puissance ou le SOC), et d'autres qui sont liés à la température ou le courant dans les différents organes.
- Le RE_Sequence qui détermine l'état du Range Extender (générateur + MCI) : éteint, démarrage, montée en puissance, en charge ou descente en puissance.
- Le MG Speed Control qui contrôle le couple du générateur électrique en fonction de la vitesse souhaitée et de la décision du module RE_sequence. Ceci est réalisé grâce à un correcteur de type PID.

3.3/ MODÉLISATION DYNAMIQUE : LA REM

La REM est un formalisme graphique pour la représentation synthétique de systèmes énergétiques multidisciplinaires [61]. Elle conduit à une description fonctionnelle d'un

système énergétique. De plus, elle respecte la causalité intégrale du système étudié, ce qui permet d'en déduire de façon systématique une structure de commande. Ce formalisme a été développé dans les années 2000 par le laboratoire d'Électrotechnique et d'Électronique de Puissance (L2EP) de Lille :

- représentation car la **REM** permet de définir une organisation synthétique et graphique d'une modélisation mathématique pour les systèmes complexes
- énergétique car la **REM** met en évidence les interactions et les échanges énergétiques des éléments qui composent un système multiphysique
- macroscopique car la **REM** permet de décrire un système sans avoir une lecture graphique trop riche (1er niveau des systèmes)

Pour une lecture simplifiée du modèle véhicule présenté dans la suite du chapitre, les tableaux 3.2 et 3.3 répertorient l'ensemble des éléments constituant le formalisme REM.

En utilisant les blocs conventionnels du formalisme, le modèle véhicule ainsi que sa chaîne de contrôle est celui présenté sur la figure 3.2. La suite de cette partie présente le formalisme REM utilisé et les équations de chaque bloc constituant le modèle en partant de l'environnement et en remontant la chaîne de traction jusqu'au moteur thermique (MCI). La commande est ensuite réalisée par inversion de chaque bloc.

Environnement

L'environnement est assimilable à une source mécanique. Il définit la résistance mécanique à l'avancement d'une roue. Les forces mises en jeu sont la force aérodynamique F_a , la résistance au roulement F_r et la force de gravité F_g (équation 3.1).

$$F_{res} = F_a + F_r + F_g \quad (3.1)$$







$$= \frac{1}{2} \rho A C_x V_{veh}^2 + \mu m_v g + m_v g \sin(\alpha) \quad (3.2)$$

avec les forces F_{res} , F_a , F_r et F_g en N, la gravité g en $m.s^{-2}$ et m_v la masse du véhicule en kg. A est la surface frontale exprimée en m^2 , ρ la densité de l'air en $kg.m^{-3}$ et C_x et μ sont respectivement le coefficients aérodynamique et le coefficient de résistance au roulement.

TABLE 3.1 – Paramètres de la Noao

Masse du véhicule	990 kg
Surface frontale	2 m^2
Coefficient de traînée aérodynamique	0,35
Coefficient de résistance au roulement	0,012
Diamètre de la roue	0,62 m
Moteur thermique	3 cylindres 1.0L, injection directe
Générateur	54 kW à 4500 tr/min, 120 N.m
Moteur électrique	280 kW de puissance maximale, 400 N.m
Pack batterie	3 batteries Lithium-ion, 520 V et 39 Ah
Transmission	Simple, ratio de 2,9, rendement de 0,95

TABLE 3.2 – Récapitulatif des éléments constitutifs du formalisme REM 1/2

Élément	Symbole	Description	Exemples
Variables		Variables d'action et de réaction	Tension(x) Courant(y)
Capteur	0	Capteur placé sur une variable	Capteur de tension, de courant, de vitesse
Source		Source d'énergie avec ou sans entrée de réglage	Alimentation électrique (continue, alternative), environnement d'un véhicule
Éléments d'accumulation		Élément d'accumulation d'énergie (causalité intégrale) avec ou sans pertes dissipatifs	Inductance, condensateur, inertie, masse
Éléments de conversion		Convertisseur monophysique (sans accumulation d'énergie) avec ou sans entrée de réglage	Transformateur électrique, convertisseur électrique, réducteur, engrenage, roue
		Convertisseur multiphysique (sans accumulation d'énergie) avec ou sans entrée de réglage	Machine à courant continu à excitation séparée
Éléments de couplage		Couplage monophysique (sans accumulation d'énergie) avec ou sans pertes	Couplage série (équicourant), parallèle (équitension), poulie-courroie (équivitesse)
		Couplage multiphysique (sans accumulation d'énergie) avec ou sans pertes	Couplage électromécanique d'une machine électrique





Chassis

En appliquant le Principe Fondamental de la Dynamique (PFD) au véhicule, on obtient l'équation 3.3

$$m\vec{a} = \sum_i \vec{F}_i \quad (3.3)$$

Appliquée à un véhicule automobile en mouvement, on obtient alors l'équation 3.4. La force nécessaire à l'accélération du véhicule est égale à la force disponible F_d aux roues et délivrée par le moteur électrique à laquelle on soustrait les forces de résistances à

TABLE 3.3 – Récapitulatif des éléments constitutifs du formalisme REM 2/2

Estimateur		Modèle ou estimateur (quelle que soit la forme)	
Inversions		Inversion d'un élément de conversion avec x1 comme entrée de perturbation (sans asservissement)	
		Inversion d'un élément avec accumulation d'énergie (avec asservissement)	
		Inversion d'un couplage neutre, par répartition ou par pondération (sans asservissement)	
Stratégie		Détermine les critères de répartition k_r , les critères de pondération k_p et les références	

l'avancement F_{res} . La masse d'inertie équivalente m_r qui caractérise l'inertie nécessaire à la mise en rotation des différents organes est décrite dans l'équation 3.5. Elle tient compte des inertie des roues I_{wh} , de l'arbre de transmission I_p et du moteur électrique I_{em} . Les rendements η_f et η_t sont considérés constant à 0,95 et les rapports de boîte i_f et i_t sont respectivement de 1 et 2,9.

$$(m_v + m_r) \frac{d}{dt} V_{car} = F_d - F_{res} \quad (3.4)$$

$$m_r = \frac{1}{r_{wh}^2} [I_{wh} + I_p \eta_f i_f^2 + I_{em} \eta_t (i_f i_t)^2] \quad (3.5)$$

Dans le cas d'un freinage, la force disponible F_d devient la force de freinage F_{br} . Cette force représente

$$(m_v + m_r) \frac{d}{dt} V_{car} = F_{br} - F_{res} \quad (3.6)$$

$$= \mu(\lambda) m_v g - F_{res} \quad (3.7)$$




FIGURE 3.2 – Présentation du modèle REM créé

Roue, transmission et arbre

La modélisation de la roue, de la transmission et de l'arbre entre le MCI et la génératrice sont assimilés à un rendement comme indiqué dans les équations (3.8) à (3.13). Concernant la roue, la force de propulsion qui la représente est directement dépendante du couple de transmission T_t en Nm et du rayon de la roue r_{wh} en m (équation 3.8). De même la vitesse de rotation de la roue ω_{wh} en rad/s, est directement proportionnelle à sa vitesse linéaire V_{wh} en m/s (équation 3.9).

$$F_d = T_t / r_{wh} \quad (3.8)$$

$$\omega_{wh} = V_{wh} / r_{wh} \quad (3.9)$$

Dans le cas d'un véhicule hybride série, le moteur électrique est directement relié aux roues par la transmission. Le rapport de transmission est donc fixe et le couple de transmission est l'image du couple du moteur électrique T_{EM} en Nm, au rapport de transmission r_g et au rendement de transmission η_t près (équation 3.10). De même, les régimes de rotation sont proportionnels et le coefficient multiplicateur est le rapport de transmission (équation 3.11).

$$T_t = \eta_t r_g T_{EM} \quad (3.10)$$

$$\omega_t = r_g \omega_{wh} \quad (3.11)$$

L'arbre mécanique entre le moteur thermique et la génératrice a pour entrée les couples de ces derniers (T_{MCI} et T_{EG}) et pour sortie la vitesse de rotation ω_{arbre} . L'énergie accumulée est proportionnelle au carré de la vitesse (équation 3.12). Le principe fondamentale de la dynamique donne alors l'équation 3.13.

$$E = \frac{1}{2} J \omega_{arbre}^2 \quad (3.12)$$

$$J \frac{d}{dt} \omega_{arbre} + f \omega_{arbre} = T_{ICE} - T_{EG} \quad (3.13)$$

Moteur électrique et Générateur

Le moteur électrique et le générateur sont des machines synchrones à aimants permanents. Pour réaliser une commande vectorielle optimale, un modèle utilisant la transformée de Park est nécessaire. Pour cela, il faut réaliser un changement de repère tel que présenté sur la figure 3.3. Le schéma électrique équivalent dans le repère de Park (d,q) est présenté sur la figure 3.4. Les équations (3.14) à (3.20) sont issus de l'interprétation physique du schéma équivalent.

Les variables indexées d'un "d" sont les variables de la composante d'axe direct tandis que celles indexées d'un "q" sont les variables de la composante d'axe en quadrature. i_d , i_q , L_d et L_q sont respectivement les intensités (en A) et les inductances (en H), λ_f représente le flux d'induction magnétique (en Wb) et p le nombre de paires de pôle.

$$T_e = 1.5p[\lambda_f i_q + (L_d - L_q)i_d i_q] \quad (3.14)$$




FIGURE 3.3 – Repère initial (A,B,C) du stator et repère (d,q) de Park (issus de [2])

Le couple délivré par la machine électrique est calculé de la même façon pour le moteur (équation 3.15) que pour la génératrice (équation 3.16). T_f représente les pertes par frottement, exprimées en Nm.

$$T_{EM} = T_e - T_f \quad (3.15)$$

$$T_{EG} = T_e - T_f \quad (3.16)$$

L'expression de la force électromotrice, e , et la relation entre cette dernière et le courant sont présentés avec les équations (3.17) et (3.19) pour la composante d'axe direct et sur les équations (3.18) et (3.20) pour la composante d'axe en quadrature.

$$e_d = L_q i_q p \omega_r \quad (3.17)$$

$$e_q = (L_d i_d + \lambda_f) p \omega_r \quad (3.18)$$

$$L_d \frac{d}{dt} i_d + R i_d = v_d + e_d \quad (3.19)$$

$$L_q \frac{d}{dt} i_q + R i_q = v_q - e_q \quad (3.20)$$

Onduleur et Redresseur

Afin de piloter le moteur électrique, un onduleur triphasé est nécessaire. Une approche simple consiste à le représenter par un vecteur de modulation $\underline{m}_{ond}$ tel que présenté dans les équations 3.21 et 3.22.




FIGURE 3.4 – Circuits électriques équivalents avec résistance de pertes fer en parallèle

$$\underline{u}_{ond} = \underline{m}_{ond} V_{bat} \quad (3.21)$$

$$\underline{i}_{ond} = \underline{m}_{ond}^t \underline{i}_{EM} \quad (3.22)$$

La sortie du générateur doit, quant à elle, être redressée pour fournir l'énergie du MCI au bus de courant continu. Dans cette optique, un redresseur triphasé est utilisé et sa modélisation est la même que pour l'onduleur précédent (équations 3.23 et 3.24).

$$\underline{u}_{red} = \underline{m}_{red} V_{bat} \quad (3.23)$$

$$\underline{i}_{red} = \underline{m}_{red}^t \underline{i}_{EG} \quad (3.24)$$

Batterie Lithium-ion

La source d'énergie primaire d'un véhicule électrique avec prolongateur d'autonomie est le pack batterie. La NOAO est composée de trois modules de batteries identiques montés en série lui permettant d'avoir une capacité de 23kWh pour une tension nominale de 520V. Les entrées du modèle permettent de déterminer l'intensité de la batterie i_{bat} en fonction de l'intensité de l'onduleur i_{ond} et du redresseur i_{red} (équation (3.25)).

$$i_{bat} = i_{ond} - i_{red} \quad (3.25)$$

Concernant la tension de la batterie, plusieurs équations sont nécessaires pour l'obtenir (3.26) à (3.28). L'équation 3.26 est empirique et valable uniquement pour les batteries lithium-ion [37]. V_{OC} représente la tension en circuit ouvert, V_{bat} représente la tension à l'intérieur de l'une des cellules et $V_{\Sigma bat}$ représente la tension totale de la batterie. Cette dernière est simplement obtenue en multipliant la tension d'une batterie par le nombre de batterie en série n_{bat} (3.28). La résistance R utilisée dans l'équation (3.27) dépend du mode fonctionnement de la batterie (charge, décharge) et du niveau de SOC normé (figure 3.5).

$$V_{OC} = -1.031 \exp(-35 SOC) + 3.685 + 0.2156 SOC - 0.1178 SOC^2 + 0.321 SOC^3 \quad (3.26)$$




FIGURE 3.5 – Valeur de la résistance interne du pack batterie de la NOAO suivant le mode de fonctionnement et le SOC

$$V_{bat} = V_{OC} - R \cdot i_{bat} \quad (3.27)$$

$$V_{\Sigma bat} = V_{bat} \cdot n_{bat} \quad (3.28)$$

On peut alors définir la puissance délivrée par la batterie (3.29) et l'état de charge de la batterie (3.30). Dans cette dernière équation, C_t représente la capacité totale de la batterie en Ah.

$$P_{bat} = i_{bat} \cdot V_{\Sigma bat} \quad (3.29)$$

$$SOC = SOC_{initial} - \frac{\int i_{bat} \cdot V_{\Sigma bat}}{C_t} \quad (3.30)$$

Moteur à Combustion Interne

Le couple du MCI, T_{MCI} , peut être estimé grâce au débit de carburant $\dot{m}_f$ et au rendement indiqué η_i (équation (3.31)). La cartographie de rendement est présentée sur la figure 3.6. Cette méthode est issue des travaux de Asus et al. [8]. Bien que simpliste, elle est suffisamment précise dans le cadre de notre étude.

$$T_{MCI} = \frac{\eta_i \dot{m}_f PCI - P_{fr}}{\omega_{arbre}} \quad (3.31)$$

P_{fr} représente les pertes par frottement et PCI représente le pouvoir calorifique du carburant considéré (de l'essence pour la NOAO).

Les pertes par frottement sont calculées par une formule analytique présentée dans l'équation 3.32,

$$P_{fr} = (f + f_p N) \frac{V_d N}{R_c 60} \quad (3.32)$$




FIGURE 3.6 – Cartographie de rendement du moteur thermique

avec f le facteur de frottement supposé constant à 100 kPa, f_p le facteur de frottement égal à 20, V_d la cylindrée en m^3 , N le régime de rotation en tr/min et le facteur R_c égal à 1 pour les moteurs 2 temps et à 2 pour les moteurs 4 temps.

3.4/ VALIDATION DU MODÈLE

En juillet 2012, la NOAO a effectué des essais sur le circuit Grand Prix de Magny-Cours et de nombreuses données ont ainsi pu être récoltées. Elles servent de comparaison aux résultats de la simulation effectuée avec le modèle précédemment créé. Le cycle considéré (figure 3.7) représente 4 tours consécutifs du circuit soit une distance totale de 17,644 km (4,411 km par tour) pour une durée de 610s (10min et 10s).




FIGURE 3.7 – Cycle de validation du modèle

La stratégie modélisée pour la validation a pour objectif de suivre le profil de vitesse en maintenant un niveau de SOC acceptable : c'est la stratégie actuellement intégrée au véhicule. La première vérification consiste donc à observer si la consigne de vitesse est respectée 3.8.




FIGURE 3.8 – Comparaison entre vitesse expérimentale et numérique


Chaque composant dont la validation est possible avec des données expérimentales est comparé sur les figures 3.9 à 3.12. Il s'agit du couple et de la puissance en sortie de moteur électrique (figure 3.9) et en sortie de génératrice (figure 3.10). De plus les caractéristiques de la batterie (intensité, tension et état de charge) sont présentées sur la figure 3.11. Enfin la consommation en carburant est présentée sur la figure 3.12. Afin d'avoir une meilleure visibilité sur la corrélation des courbes, un zoom a été effectué sur le 2ème tour pour chaque composant.

En remontant la chaîne de traction on observe tout d'abord qu'on obtient une modélisation acceptable du moteur électrique, tant en couple (figure 3.9a) qu'en puissance (figure 3.9b). En effet, les écarts les plus importants sont présents en phase de fortes accélérations (immédiatement après un freinage), ce qui représente les phases transitoires les plus délicates à modéliser. Les fréquences d'échantillonnage étant différentes entre les résultats du calcul et les données enregistrées, l'utilisation d'un filtre de Butterworth permettrait d'obtenir des courbes lissées et plus proche de l'expérimentale. La dynamique plus importante pour le modèle est aussi dû au réglage du PID. Pour la génératrice, l'analyse est transposable, d'autant que les résultats sont davantage précis.


Concernant la batterie, on observe une différence au niveau de la tension (figure 3.11a) et de l'intensité (figure 3.11b). En effet, lors des phases de freinage, le modèle surestime l'intensité nécessaire à la récupération d'énergie. L'état de charge (figure 3.11c) est quand à lui très proche des résultats expérimentaux (écart <1%).

L'évolution de la consommation de carburant (figure 3.12) montre une légère surestimation de la consommation (2,6%) ce qui reste cohérent au vue du modèle utilisé.

Le modèle est donc suffisamment précis dans le cadre de notre étude puisque le comportement de l'ensemble des composants est fidèlement représenté, ce qui le rend valide pour la suite des travaux.




(a) Couple




(b) Puissance

FIGURE 3.9 – Comparaison des résultats du moteur électrique entre expérimentaux et numériques




(a) Couple




(b) Puissance


FIGURE 3.10 – Comparaison des résultats de la génératrice entre expérimentaux et numériques



(a) Tension



(b) Intensité



(c) SOC

FIGURE 3.11 – Comparaison des résultats de la batterie entre expérimentaux et numériques




FIGURE 3.12 – Comparaison entre consommation de carburant expérimentale et numérique

3.5/ COMPARAISON AVEC L'APPROCHE QUASI-STATIQUE

Dans le cadre de l'optimisation globale effectuée avec la DP, une approche quasi-statique a été adoptée pour modéliser le véhicule. Ce choix a été fait pour limiter le temps de calcul étant donné que la DP est une méthode lourde en temps de calcul. Le but de cette partie est de quantifier l'écart imputable à la différence de modèle.

La principale différence entre un modèle quasi statique et un modèle dynamique réside dans l'absence de boucle de rétroaction. De plus, la modélisation précise des organes tels que le moteur électrique et le générateur est remplacée par une cartographie de rendement en fonction du couple et du régime de rotation (figures 3.13 et 3.14). Ces deux cartographies sont issues des données constructeurs.




FIGURE 3.13 – Cartographie de rendement du moteur électrique




FIGURE 3.14 – Cartographie de rendement de la génératrice

En outre la modélisation de la batterie et du MCI reste inchangée.

Dans cette partie, l'objectif est de quantifier l'écart induit par la différence de modèle afin de vérifier qu'il est possible d'utiliser les résultats de la DP sur un modèle dynamique.


TABLE 3.4 – Ecart relatif de résultat entre modèle quasi-statique et REM

Grandeurs	Cycle	Vitesse	Consommation (L)	SOC
Valeurs finales modèle quasi-statique	rampe	/	0.523	0.370
	WLTC	/	2.207	0.370
	réel	/	0.839	0.370
Valeurs finales modèles dynamique	rampe	/	0.523	0.370
	WLTC	/	2.164	0.363
	réel	/	0.839	0.398
Ecart relatif	rampe	0%	0%	0%
	WLTC	0%	2%	1.9%
	réel	5%	0%	7%


Pour cela, on utilise dans un premier temps la Programmation Dynamique pour déterminer la répartition de puissance optimale. Ce calcul est effectué en utilisant un modèle quasi statique. Dans un deuxième temps, le résultat de la DP est utilisé comme stratégie du modèle dynamique. La comparaison est alors réalisée sur 3 cycles différents : une rampe, le cycle normalisé WLTC et un cycle réel issus de la campagne d'essai décrite dans le chapitre 2. Ces cycles sont présentés sur la figure 3.15. Les résultats sont présentés sur les figures 3.15 à 3.20. Pour l'ensemble des grandeurs, la courbe de la référence (issue de la DP) est représentée en rouge alors que la courbe issue de l'approche dynamique est représentée en bleu.

On observe globalement un respect de la consigne de vitesse pour l'ensemble des trajets. Une différence est toutefois à noter pour le cycle réel. Elle provient de la pente initiale qui a été créée artificiellement puisque la première vitesse enregistrée lors des essais n'est pas nulle, à cause du temps de synchronisation du GPS avec les satellites. Dans le cas du modèle quasi statique, il est tout à fait possible de passer d'un point de cartographie à un autre, ce qui permet le respect de la consigne. Le modèle dynamique, quant à lui, ne permet pas d'effectuer un tel démarrage.


A l'exception du cycle réel, l'analyse de ces courbes démontre que les 2 approches donnent des résultats proches (écart inférieur à 5%) sur les 3 grandeurs principales que sont la vitesse, la consommation et l'état de charge de la batterie. Concernant le cycle réel, le fait de ne pas strictement respecter le cycle de vitesse induit un écart de 5% en terme d'énergie. Cela conduit inévitablement à un excédent sur le SOC finale de la batterie (7%). Le modèle ne semble donc pas être en cause dans l'obtention de ces résultats. Cela permet donc de réaliser la programmation dynamique en utilisant un modèle quasi statique et d'utiliser les résultats dans un modèle dynamique afin de gérer la stratégie temps réel.



(a) Vitesse sur rampe




(b) Vitesse sur WLTC




(c) Vitesse sur cycle réel

FIGURE 3.15 – Respect de la consigne de vitesse sur les 3 cycles considérés pour les deux approches




(a) Consommation




(b) Ecart de consommation

FIGURE 3.16 – Consommation pour les 2 approches sur le cycle rampe



(a) Consommation



(b) Ecart de consommation

FIGURE 3.17 – Consommation pour les 2 approches sur un cycle réel






FIGURE 3.18 – État de charge de la batterie pour les 2 approches sur le cycle rampe



(a) SOC



(b) Ecart de SOC

FIGURE 3.19 – Etat de charge de la batterie pour les 2 approches sur le cycle WLTC




FIGURE 3.20 – État de charge de la batterie pour les 2 approches sur un cycle réel

3.6/ OPTIMISATION ÉNERGÉTIQUE

Nous disposons à présent d'un outil de prédiction de cycle et d'un modèle de véhicule. Il reste donc à établir une stratégie de gestion énergétique. Les enjeux de cette stratégie sont le respect d'une consigne de vitesse qui se trouve être le cycle réalisé par l'automobiliste et le maintien du niveau de SOC au dessus d'un seuil bas défini à 30% pour éviter d'endommager la batterie avec une décharge profonde. L'objectif de la stratégie est la minimisation de la consommation. Pour cela, deux méthodes d'optimisation ont été utilisées. La première est la DP, présentée dans la section 1.3.2.1, et la seconde est une méthode basée sur les moindres carrées et inspirée du MPC. Pour chacune des stratégies, le principe général appliqué à notre cas d'étude est présenté, puis les résultats de la stratégie sur différents cycles sont affichés.

3.6.1/ PROGRAMMATION DYNAMIQUE

La Programmation Dynamique introduite dans la section 1.3.2.1 est utilisée dans la stratégie de gestion énergétique comme outil de benchmarking mais servira aussi de base à la stratégie en temps réel. Elle nécessite la connaissance parfaite du cycle de conduite pour être optimale ce qui n'est, en réalité, pas possible à cause des aléas de la route.

3.6.1.1/ MISE EN ÉQUATION DU PROBLÈME

L'objectif de la Programmation Dynamique est de déterminer, hors ligne, la répartition de puissance optimale entre le moteur thermique et la batterie afin de minimiser la consommation de carburant. A l'aide du modèle quasi-statique créé, l'optimisation du système se résume à la minimisation de la fonction coût, J , tel que définit dans l'équation 3.33. La fonction coût optimal est alors noté J^* . G et H sont des fonctions représentant respectivement le coût final et le coût instantané.

$$J^* = \min J(u(t)) \quad (3.33)$$

$$J(u(t)) = G(x(t_f)) + \int_0^{t_f} H(x(t), u(t), t) dt \quad (3.34)$$

L'évolution de la variable d'état notée $\dot{x}_t$ est représentée par la fonction F qui dépend de la variable d'état et des variables d'entrée à l'instant t (3.35). La résolution du problème se fait par pas de temps, appelé T_s . Le nombre de pas de temps nécessaire est alors défini comme étant le rapport entre la longueur du problème (temps total) L_N et le pas de temps.

$$\dot{x}_t = F(x_t, u_t, t) \quad (3.35)$$

$$N = \frac{L_N}{T_s} + 1 \quad (3.36)$$

$$x(t) \in [x_{min} \ x_{max}] \quad (3.37)$$

L'algorithme implémenté dans Matlab a été développé par O. Sundström et L. Guzzella [115] et a été modifié afin de répondre aux besoins de l'étude. Appliqué à nos travaux de recherche, le problème est formulé avec les équations 3.38 à 3.42. La variable d'état considérée, x , est l'état de charge de la batterie (SOC) dont l'équation 3.39 donne l'expression. La variable d'entrée est la répartition énergétique noté u et définie dans l'équation 3.40.

$$J = \int_0^{N-1} \dot{m}_{fuel} T_s \quad (3.38)$$

$$SOC_{k+1} = SOC_k + \frac{V_{batt} - \sqrt{V_{batt}^2 - 4P_{batt}R_i}}{2R_iQ} \quad (3.39)$$

$$u = \frac{P_{MCI}}{P_{tot}} \quad (3.40)$$

$$x(t) \in [0.1 \ 0.9] \quad (3.41)$$

$$u(t) \in [-1 \ 1] \quad (3.42)$$

La consommation de carburant est représentée par $\dot{m}_{fuel}$ et exprimée en g/s. V_{batt} et P_{batt} désigne respectivement la tension, en V, et la puissance délivrée par la batterie, en W. La capacité de la batterie est notée Q , exprimée en Ah, et sa résistance R_i , en Ω . Enfin, P_{MCI} représente la puissance délivrée par le moteur thermique et P_{tot} la puissance nécessaire pour réaliser le cycle de vitesse, toutes les deux en W.

3.6.1.2/ APPLICATION DE LA DP DU CYCLE LE PLUS REPRÉSENTATIF

En se référant à l'étude bibliographique du chapitre 2, une stratégie de gestion énergétique en temps réel (MPC ou ECMS) semble être la meilleure solution pour minimiser la consommation d'un véhicule pour un trajet. Mais au vue de la méthode de prédiction de cycle basée sur le cycle le plus représentatif, il est devenu intéressant de tester l'utilisation de la DP de ce cycle représentatif sur l'ensemble des trajets qui sont identiques. Cela permet d'une part de valider le besoin d'utiliser une méthode en temps réel et d'autre part de quantifier le gain maximal que pourra apporter une telle méthode.

En pratique, pour chaque conducteur de la base de données, le cycle le plus représentatif de chaque trajet réalisé plus d'une fois a été défini via la méthode d'inter-corrélation présentée dans le paragraphe (2.2.1). La DP a été appliquée à ce cycle ce qui a permis d'obtenir la répartition énergétique optimale sur celui-ci. Le vecteur de commande optimale exprimé en fonction de la distance parcourue est ensuite utilisé comme paramètre

TABLE 3.5 – Résultats comparatif de l'application de la DP du cycle le plus représentatif sur les autres cycles d'un même trajet

Cycle	1	2	3	4	5
Facteur de corrélation	0.983	0.979	0.976	0.981	1
DP consommation (L)	0.73	0.64	0.61	0.73	0.70
Stratégie du cycle 5 (L)	0.79	0.67	0.65	0.77	0.70
Facteur d'optimalité	92.4	95.5	93.8	94.8	/
Ecart	7.6	4.5	6.2	5.2	/

d'entrée du modèle REM pour chaque cycle représentant le même trajet. Les résultats pour un cas d'étude issus de la base de données sont présentés dans le tableau 3.5. Afin de quantifier la performance de cette méthode, le facteur d'optimalité est calculé. Il est défini comme étant le rapport entre la consommation de la DP et la consommation de la méthode online (3.43).

L'exemple pris est représentatif de l'ensemble de la base de donnée puisque l'écart moyen sur tous les trajets d'au moins 2 occurrences est de 5.8%. Cela justifie l'utilisation d'une méthode en temps réel.

$$\Gamma = \frac{\text{conso}(DP)}{\text{conso}(online)} \times 100 \quad (3.43)$$

3.6.2/ MÉTHODE D'OPTIMISATION TEMPS RÉEL

Dans l'optique d'une stratégie en temps réel, le MPC a été retenu pour sa capacité d'adaptation aux conditions de trafic (section 1.3.2.2). En effet, il est nécessaire de tenir compte de l'inertie de la commande moteur afin de réagir rapidement aux changements de conditions. Ainsi avec le MPC, la réponse du système à une commande est identifiée et modélisée. Cela permet, en anticipant la future volonté conducteur, de calculer la suite de commandes optimales qui permet de respecter la vitesse à la fin de l'horizon de prédiction. Le principe de modélisation ainsi que la mise en équation du problème sont présentés dans le paragraphe suivant. Enfin, les résultats obtenus sont exposés et comparés à la DP afin de situer leur niveau d'optimalité.

3.6.2.1/ PRINCIPE DE LA RÉOLUTION NUMÉRIQUE PAR MPC

La résolution du problème par le MPC se base sur le choix d'un horizon de prédiction t_h qui correspond à un nombre d'itération n_h . Tout comme pour la DP, le système est évalué par une fonction objectif (ou coût) qu'il doit minimiser à la fin de l'horizon de prédiction. L'identification du modèle de réponse du système est définie hors ligne, puis la commande prédictive est réalisée en 3 étapes :

1. L'objectif est calculé
2. Par calcul itératif, la trajectoire de commande désirée est déterminée

3. La minimisation du critère est effectuée : pour cela un critère quadratique est défini comme l'écart entre la trajectoire de référence et la sortie estimée. Un algorithme de minimisation est alors utilisé pour assurer au mieux la convergence vers l'objectif.

Finalement, la première commande issue du résultat est appliquée et le processus est répété à l'instant suivant jusqu'à atteindre le temps final du problème.

De manière générale, un modèle prédictif se présente sous la forme suivante (3.44 et 3.45) :

$$x(t) = Ax(t-1) + Bu(t) \quad (3.44)$$

$$y(t) = Cx(t) + Du(t) \quad (3.45)$$

avec x le vecteur des variables d'états, u le vecteur des variables d'entrée et y le vecteur des variables de sorties. A , B , C et D sont les matrices d'évolution des différents paramètres.

Le cas considéré dans ces travaux est soumis à des contraintes physiques et dynamiques, ce qui nécessite une résolution par programmation quadratique (quadratic programming QP en anglais).

3.6.2.2/ PRÉSENTATION DE LA STRATÉGIE TEMPS RÉEL UTILISÉE

Dans notre cas, le principe de la stratégie de gestion énergétique mise en place est présenté sur la figure 3.21. Au départ du trajet, l'algorithme cherche dans sa matrice de trajets enregistrés quels sont les trajets susceptibles d'être réalisés et en extrait les probabilités (1). Elle sélectionne le trajet le plus probable, et récupère la DP du cycle le plus représentatif correspondant à ce trajet (2 et 3). La méthode d'optimisation présentée précédemment est alors appliquée, et toutes les x secondes, le trajet est vérifiée (4 et 5). Si les coordonnées à l'instant t sont toujours susceptibles de correspondre au trajet sélectionné alors la stratégie se poursuit (7), sinon la première partie est de nouveau appliquée pour sélectionner un nouveau trajet (8 et 9). Lorsque le trajet est terminé, la base de données est mise à jour (10) et en cas de changement de cycle le plus représentatif, la DP du nouveau cycle est réalisée (11).

Dans l'hypothèse où les probabilités tombent à 0 (nouveau trajet jamais enregistré), la solution suivante est envisagée. Elle consiste à demander au conducteur de renseigner sa destination. S'il accepte, alors la DP est réalisée en se basant sur les limitations de vitesse. S'il refuse, une méthode de CD/CS (décharge puis maintien de charge) basée sur des règles est appliquée. Cependant ces solutions proposées n'ont pas pu être codées dans la durée de la thèse.

3.6.2.3/ LINÉARISATION DU PROBLÈME

Afin de pouvoir résoudre le problème d'optimisation en utilisant une méthode prédictive, il est nécessaire d'effectuer une linéarisation des variables d'états et des variables de sorties. Pour cela, une étude sur la consommation a permis de représenter cette dernière en fonction des variables d'entrée T_{MCI} et ω_{MCI} qui sont respectivement le couple et le




FIGURE 3.21 – Schéma bloc de la stratégie de gestion énergétique créée

régime de rotation du moteur thermique. La fonction est telle que définie dans l'équation 3.46.

$$\dot{m} = \alpha T_{MCI} + \beta \omega_{MCI} + \gamma T_{MCI}^2 + \theta \omega_{MCI}^2 \quad (3.46)$$

avec $\alpha, \beta, \gamma, \theta$ les coefficients déterminés par une méthode de curve fitting.

La corrélation entre la cartographie moteur et les points donnés par le modèle linéaire est présentée sur la figure 3.22. Une validation fonctionnelle du modèle linéaire a été réalisée en utilisant les cycles ayant servis à la validation du modèle quasi-statique. Les résultats sont présentés sur la figure 3.23.







FIGURE 3.22 – Comparaison entre cartographie initiale et points issus du modèle linéaire



(a) Conso sur la rampe



(b) Conso sur le WLTC



(c) Conso sur un cycle issu de la base de données

FIGURE 3.23 – Validation de la linéarisation pour plusieurs cycles de référence

On observe une reproduction fidèle de la consommation avec la linéarisation utilisée, et ce pour les trois cycles considérés.

3.6.2.4/ VALIDATION DE LA STRATÉGIE

Tout d'abord, il a été démontré que la longueur de l'horizon glissant est importante pour cette méthode d'optimisation [9, 34]. Une étude sur ce paramètre a donc été réalisée. Pour cela un même cycle a été rejoué plusieurs fois pour un horizon allant de 0 s à l'intégralité du cycle. Ce dernier cas équivaut donc à appliquer la DP. Les résultats en terme de consommation sont présentés dans le tableau 3.6. Le cycle considéré est quant à lui présenté sur la figure 3.24. Il semble cohérent de pouvoir anticiper jusqu'à 1 minute de trajet et, au vue du résultat d'optimalité pour cet horizon de prédiction, cette valeur sera prise pour la suite des études. Toutefois, une piste d'amélioration semble être l'utilisation d'un horizon de prédiction variable au cours du trajet, en fonction de la vitesse véhicule et du type de route sur laquelle circule l'automobiliste.




FIGURE 3.24 – Profil considéré pour l'étude de l'impact de l'horizon de prédiction

TABLE 3.6 – Optimalité de la stratégie en fonction de l'horizon de prédiction choisi

Horizon de prédiction (s)	10	20	30	40	50	60	120
Optimalité sur cycle BdD	0.92	0.934	0.951	0.960	0.971	0.987	0.991

La stratégie mise en place a ensuite été testée et validée sur l'ensemble de la base de données. Il existe deux cas possibles : les trajets dont la prédiction initiale est juste, et ceux qui connaissent un changement de prédiction durant la simulation. Comme expliqué précédemment, les trajets uniques ne font pas l'objet de la stratégie mise en place et ne sont donc pas considérés dans ce paragraphe.

La figure 3.25 représente le cas où la prédiction initiale est correcte sur l'intégralité de la base de données. Sont exclus les trajets uniques.

Dans le cas où la prédiction initiale, s'avère ne pas être correcte, l'optimalité diminue (figure 3.26). On constate qu'à partir de 3 changements, la stratégie utilisée n'apporte




FIGURE 3.25 – Répartition de l'optimalité de la stratégie

plus assez de bénéfice par rapport à une méthode basée sur des règles. Elle ne comporte donc plus d'intérêt au vue de la complexité de mise en oeuvre. Cela confirme toute l'importance de la prédiction du cycle de conduite dans la méthode employée. Les changements ne sont pas créés, ils appartiennent à la base de données. C'est à dire qu'une fois la base constituée intégralement, chaque scénario est simulé en fonction des probabilités et certains trajets ont un ou plusieurs changement(s) de prédiction.

Certains de ces changements sont récurrents. Il s'agit principalement de trois types de trajets :

- un détour exceptionnel le matin pour poser les enfants avant d'aller au travail
- un détour pour faire des courses en rentrant du travail
- un trajet pour le sport depuis son lieu de travail

Dans le troisième cas, il est fortement possible qu'une prise en compte, à minima du jour, voir de l'heure de départ puisse améliorer la prédictibilité des trajets. A l'inverse, il est fort probable que dans le deuxième cas le jour soit aléatoire. Enfin, dans le premier cas il est dur de se prononcer car l'on conçoit aisément qu'il puisse exister les 2 possibilités de fonctionnement.

Dans l'hypothèse où la prédiction est bonne dès le point de départ, la quasi optimalité n'est pas garantie. En effet, en cas de perturbations du trafic entraînant une baisse significative de la vitesse, la stratégie doit être capable de s'adapter. L'impact d'une baisse de la vitesse de 110 km/h à 90 km/h, dans l'hypothèse où elle est connu en avance, est présenté sur la figure 3.27. On constate une importante modification de la stratégie et son impact sur la consommation est immédiat. Ici le SOC initial est de 0.9 et le SOC final de 0.3. La consommation de carburant est divisée par 5 dans ce cas test étant donnée que le trajet est presque réalisable en tout électrique, ce qui n'est pas représentatif de la majorité des cas. Dès lors que le SOC initial est à 0.6, la consommation passe de 0.32 L en condition de trafic perturbée à 0.51 L en condition fluide (figure 3.28).







FIGURE 3.26 – Optimalité moyenne en fonction du nombre de changement de prédiction




(a) Cycle de vitesse



(b) Débit instantané de carburant (g/s)




(c) Carburant consommé (L)




(d) SOC


FIGURE 3.27 – Impact de l'anticipation du ralentissement sur les différents paramètres à $SOC_{init} = 0.9$



(a) Débit instantané de carburant (g/s)



(b) Carburant consommé (L)



(c) SOC

FIGURE 3.28 – Impact d'un ralentissement sur les différents paramètres à $SOC_{init} = 0.6$

Afin de déterminer le niveau d'information nécessaire pour être en mesure d'optimiser la stratégie, une étude a été réalisée sur le temps d'anticipation. La plage considérée varie entre la connaissance du ralentissement dès le début du parcours et la non information de trafic perturbé. Les instants à partir desquels le ralentissement est détecté sont représentés sur la figure 3.29. La répartition d'énergie qui en découle est présentée sur la figure 3.30 à travers l'évolution du SOC et de la consommation carburant. La référence de comparaison est la courbe appelée "parcours sans connaissance", qui est l'adaptation en temps réel sans aucune anticipation sur les conditions de trafic. On constate que plus les aléas sont détectés rapidement, meilleure est l'optimisation énergétique. Cela renforce la nécessité d'utiliser un ITS afin de connaître les conditions de circulation en direct. Afin de conserver une bonne optimalité, il faut s'assurer que le timing d'anticipation du ralentissement soit supérieur à l'horizon de prédiction, ce qui paraît raisonnable et facilement intégrable.





FIGURE 3.29 – Timing d'anticipation du ralentissement. De gauche à droite 180,120,90,60,30,20,10 et 0 s


3.6.3/ CONCLUSION

Ce chapitre présente la modélisation d'un véhicule hybride série de type Range Extender ainsi que la validation de ce modèle. La méthode employée est la REM, qui est une méthode causale permettant de mettre en évidence, de manière graphique, les interactions et les échanges énergétiques des éléments d'un système multi-physique. Le contrôle est effectué grâce à une méthode d'inversion. Les résultats numériques ont été comparés aux relevés expérimentaux, permettant ainsi de valider la robustesse du modèle avec une précision suffisante.

En s'appuyant sur l'étude bibliographique du chapitre 1, il a été décidé de coder deux stratégies de gestion énergétique. La Programmation Dynamique étant considérée comme référence, elle est à la fois utilisée pour la comparaison de la seconde stratégie et pour l'apprentissage hors ligne. En effet, il est nécessaire de pouvoir quantifier l'optimalité de la stratégie temps réel, afin d'améliorer ses résultats tout au long de la vie du véhicule. La seconde stratégie est basée sur le MPC et permet d'assurer une quasi optimalité quelque soit les perturbations rencontrées.



(a) Impact sur la consommation



(b) Impact sur la l'état de charge de la batterie

FIGURE 3.30 – Timing et impact de l'anticipation du ralentissement

L'utilisation de ces stratégies ainsi que leur impact sur la consommation et l'état de charge de la batterie ont été démontrés au cours de ce chapitre. Quelques points d'attention sont toutefois à observer notamment sur le dimensionnement de l'horizon de prédiction. De plus, il sera nécessaire lors de l'intégration de la méthode de l'interfacer à un ITS, capteur qui tend à se démocratiser sur le marché de l'automobile.

CONCLUSION ET PERSPECTIVE

Les travaux de thèse présentés ont pour vocation d'apporter une solution, parmi d'autres, au défi environnemental actuel, et plus particulièrement en matière de consommation des véhicules hybrides. Partant du constat que les véhicules hybrides actuels permettent une augmentation de l'efficacité énergétique mais peuvent encore être optimisés par une gestion intelligente de l'énergie, il a été décidé d'explorer plusieurs pistes pour remédier à ceci. Afin de mener à bien ces travaux, le manuscrit est scindé en trois parties distinctes.

Le premier chapitre présente les principales stratégies utilisées dans la gestion énergétique des véhicules hybrides. Les deux familles sont analysées et critiquées afin d'en extraire les avantages et inconvénients. Par cette analyse critique, il apparaît que la connaissance du cycle de conduite à venir permettrait d'adapter et optimiser la gestion énergétique. Cependant, l'une des contraintes majeures à l'utilisation systématique des outils de localisation, tels que le GPS, réside dans l'obligation pour le conducteur de renseigner sa destination, et ce quelque soit le trajet à effectuer. Ceci semble être une solution beaucoup trop contraignante pour être efficace au quotidien. En conséquence, afin de disposer de suffisamment de données, une étude expérimentale a été menée sur la base du volontariat. Concernant les stratégies, deux méthodes d'optimisation complémentaires ont été retenues et utilisées. La première s'exécute en temps réel afin de choisir à chaque instant la répartition d'énergie tout en s'adaptant aux aléas de trafic. Il s'agit du Model Predictive Control (MPC). La seconde est réalisée hors ligne et sert à la fois de référence à la première, et de benchmark à la fin du cycle. Il s'agit de la Programmation Dynamique (DP).

La campagne d'essai réalisée sur 40 personnes, 1625 trajets et plus de 13 000 km a permis de mettre en avant la répétabilité de certains trajets, notamment en semaine, ce qui donne tout son sens à une méthode d'optimisation prédictive. Les travaux démontrent le réel intérêt d'une telle méthode et mettent en avant l'impact prépondérant de la qualité de la prédiction. Il serait donc intéressant de mener une campagne d'essai plus importante, tant en nombre d'automobilistes qu'en durée. Ainsi l'impact du jour de la semaine et de l'horaire de départ pourrait être étudié. Les études de mobilité existantes démontrent que les déplacements sont pendulaires, ce qui laisse penser que la prédiction puisse être améliorée.

Un modèle de véhicule basée sur la Représentation Énergétique Macroscopique (REM) a été développé dans le chapitre 3 afin de mettre en place la commande du système par inversion. Pour valider la pertinence du modèle, les résultats numériques ont été comparés à des enregistrements expérimentaux effectués en 2012 sur le circuit de Magny-Cours. Le modèle mis en place est considéré suffisamment représentatif pour observer le comportement dynamique du véhicule.

Cependant il existe deux améliorations possibles à intégrer dans la commande. La première consiste à tenir compte de la thermique de la batterie, afin de limiter son utilisation et ainsi prolonger sa durée de vie. La seconde concerne l'intégration de la formation de polluant afin de respecter les normes environnementales actuellement en vigueur. Cette

problématique fait l'objet d'une thèse entre le laboratoire DRIVE EA1859 et l'IFSTTAR depuis 2017. La difficulté de cette problématique réside dans la contradiction entre réduction de la consommation et réduction des polluants

BIBLIOGRAPHIE

- [1] Le projet noao.
- [2] Modèle de park de la machine asynchrone.
- [3] Les véhicules électriques, 2014.
- [4] ADEME. Stratégie Transports et Mobilité. Période 2014-2017. page 25, 2014.
- [5] Meisam Amiri, Mohsen Esfahanian, Mohammad Reza Hairi-Yazdi, and Vahid Esfahanian. Minimization of power losses in hybrid electric vehicles in view of the prolonging of battery life. *Journal of Power Sources*, 190(2) :372–379, 2009.
- [6] Michel André. The ARTEMIS European driving cycles for measuring car pollutant emissions. *Science of The Total Environment*, 334-335 :73–84, 2004.
- [7] Zainab Asus, Daniela Chrenko, El-hassane Aglzim, Athmane Kebairi, Alan Kéromnes, and Luis Le Moyne. Model and Control Strategy Simulation of a Racing Series Hybrid Car. In *IEEE Vehicular Power and Propulsion Conference (VPPC)*, pages 1–6, 2014.
- [8] Zainab Asus, Daniela Chrenko, El Hassane Aglzim, Alan Kéromnès, and Luis Le Moyne. Simple method of estimating consumption of internal combustion engine for hybrid application. In *2012 IEEE Transportation Electrification Conference and Expo, ITEC 2012*, 2012.
- [9] Michael Back, Matthias Simons, Frank Kirschbaum, and Volker Krebs. Predictive Control of Drivetrains. *Proceedings of the 2002 IFAC World Congress*, 15 :1506–1506, 2002.
- [10] F Badin, F Le Berr, G Castel, J C Dabadie, H Briki, P Degeilh, and M Pasquier. Energy efficiency evaluation of a Plug-in Hybrid Vehicle under European procedure , Worldwide harmonized procedure and actual use. (July), 2015.
- [11] Harpreetsingh Banvait, Student Member, and Jianghai Hu. Energy Management Control of Plug-in Hybrid Electric Vehicle using Hybrid Dynamical Systems Set of discrete inputs. XX(X) :1–13.
- [12] Mohamed Ben-marzouk, Guy Clerc, Serge Pelissier, Ali Sari, Pascal Venet, Université De Lyon, Ampère Cnrs Umr, Ecole Centrale De Lyon, Université Claude, Bernard Lyon, and Université De Lyon. Determination of the electric vehicles driving modes in real life conditions by classification methods. 2016.
- [13] J. Bernard, S. Delprat, T.M. Guerra, and F.N. Büchi. Fuel efficient power management strategy for fuel cell hybrid powertrains. *Control Engineering Practice*, 18(4) :408–417, apr 2010.
- [14] Stewart Birrell, James Taylor, Andrew McGordon, Joonwoo Son, and Paul Jennings. Analysis of three independent real-world driving studies : A data driven and expert analysis approach to determining parameters affecting fuel economy. *Transportation Research Part D : Transport and Environment*, 33 :74–86, 2014.

- [15] Henry A. Bonges and Anne C. Lusk. Addressing electric vehicle (EV) sales and range anxiety through parking layout, policy and regulation. *Transportation Research Part A : Policy and Practice*, 83 :63–73, 2016.
- [16] a Brahma, Y Guezennec, and G Rizzoni. Optimal energy management in series hybrid electric vehicles. *American Control Conference, 2000. Proceedings of the 2000*, 1(June) :60–64 vol.1, 2000.
- [17] K.L. Butler, M. Ehsani, and P. Kamath. A Matlab-based modeling and simulation package for electric and \nhybrid electric vehicle design. *IEEE Transactions on Vehicular Technology*, 48(6) :1770–1778, 1999.
- [18] E. F. Camacho and C. Bordons. *Model Predictive control*. 2007.
- [19] P. Caratozzolo, M. Serra, and J. Riera. Energy management strategies for hybrid electric vehicles. *IEEE International Electric Machines and Drives Conference, 2003. IEMDC'03*, 1 :241–248.
- [20] S. Caux, W. Hankache, M. Fadel, and D. Hissel. On-line fuzzy energy management for hybrid fuel cell systems. *International Journal of Hydrogen Energy*, 35(5) :2134–2143, 2010.
- [21] Kamil Çağatay Bayindir, Mehmet Ali Gözükcük, and Ahmet Teke. A comprehensive overview of hybrid electric vehicle : Powertrain configurations, powertrain control techniques and electronic control units. *Energy Conversion and Management*, 52(2) :1305–1313, feb 2011.
- [22] CCFA. Le marché automobile français. 2018.
- [23] K. T. Chau, Y. S. Wong, and C. C. Chan. Overview of energy sources for electric vehicles. *Energy Conversion and Management*, 40(April 1998) :1021–1039, 1999.
- [24] K.T Chau and Y.S Wong. Overview of power management in hybrid electric vehicles. *Energy Conversion and Management*, 43(15) :1953–1968, oct 2002.
- [25] Bo-Chiuan Chen, Yuh-Yih Wu, and Hsien-Chi Tsai. Design and analysis of power management strategy for range extended electric vehicle using dynamic programming. *Applied Energy*, 113 :1764–1774, jan 2014.
- [26] Haibo Chen, Susan Grant-Muller, Lorenzo Mussone, and Frank Montgomery. A study of hybrid neural network approaches and the effects of missing data on traffic forecasting. *Neural Computing & Applications*, 10(3) :277–286, 2001.
- [27] Keyu Chen, Alain Bouscaryrol, and Walter Lhomme. Energetic Macroscopic Representation and Inversion-based Control : Application to an Electric Vehicle with an Electric Differenetal. *Journal of Asian Electric Vehicles*, 6 :1097–1102, 2008.
- [28] Zheng Chen, Chris Chunting Mi, Rui Xiong, Jun Xu, and Chenwen You. Energy management of a power-split plug-in hybrid electric vehicle based on genetic algorithm and quadratic programming. *Journal of Power Sources*, 248 :416–426, 2014.
- [29] D Chrenko and S Gan. Novel Classification of Control Strategies for Hybrid Electric Vehicles. *Vehicle Power and . . .*, 2015.
- [30] Daniela Chrenko. Influence of hybridisation on eco-driving habits using realistic driving cycles. *IET Intelligent Transport Systems*, 9(5) :498–504, 2015.
- [31] O. Cordon, F. Gomide, F. Herrera, F. Hoffmann, and L. Magdalena. Ten years of genetic fuzzy systems : Current framework and new trends. *Fuzzy Sets and Systems*, 141(1) :5–31, 2004.

- [32] María Laura T Cossio, Laura F Giesen, Gabriela Araya, María Luisa S Pérez-Cotapos, RICARDO LÓPEZ VERGARA, Maura Manca, R. A. Tohme, S. D. Holmberg, Tim Bressmann, Daniel Rodrigues Lirio, Jelitza Soto Román, Rodrigo Ganter Solís, Sanjay Thakur, SVD Nageswara Rao, E L Modelado, Artificial D E La, Cabeza Durante, U N A Tradición, Maya En, E L Espejo, D E L A S Fuentes, Universidad Autónoma De Yucatán, Cruz Moreno Lenin, Laura Franco Cian, M Joanne Douglas, La Plata, and Françoise Héritier. *No Title No Title*, volume XXXIII. 2012.
- [33] A Da Costa, N Kim, F Le Berr, N Marc, F Badin, and A Rousseau. Fuel Consumption Potential of Different Plug-in Hybrid Vehicle Architectures in the European and American Contexts. 5 :159–172, 2012.
- [34] M. Debert, G. Colin, Y. Chamailard, L. Guzzella, a. Ketfi-Cherif, and B. Bellicaud. Predictive energy management for hybrid electric vehicles - Prediction horizon and battery capacity sensitivity. *IFAC Proceedings Volumes (IFAC-PapersOnline)*, pages 270–275, 2010.
- [35] R. Eberhart and Yuhui Shi. Comparison between Genetic Algorithms and Particle Swarm Optimization. *Lecture Notes in Computer Science : Evolutionary Programming VII*, 1447 :611–616, 1998.
- [36] Ihab El-Shawarby, Kyoungcho Ahn, and Hesham Rakha. Comparative field evaluation of vehicle cruise speed and acceleration level impacts on hot stabilized emissions. *Transportation Research Part D : Transport and Environment*, 10(1) :13–30, 2005.
- [37] O. Erdinc, B. Vural, and M. Uzunoglu. A dynamic lithium-ion battery model considering the effects of temperature and capacity fading. In *Clean Electrical Power, 2009 International Conference on*, pages 383 – 386, 2009.
- [38] Eva Ericsson. Independent driving pattern factors and their influence on fuel-use and exhaust emission factors. *Transportation Research Part D : Transport and Environment*, 6 :325–345, 2001.
- [39] Jeffrey Gonder and Tony Markel. Energy Management Strategies for Plug-In Hybrid Electric Vehicles Distance. pages 1–5, 2007.
- [40] Qiuming Gong, Yaoyu Li, and Zhong-ren Peng. Trip-Based Optimal Power Management of Plug-in Hybrid Electric Vehicles. *Vehicular Technology, IEEE Transactions on*, 57(6) :3393–3401, 2008.
- [41] Lino Guzzella and Antonio Sciarretta. *Vehicle Propulsion Systems*. 2013.
- [42] M. H. Hajimiri and F. R. Salmasi. A Fuzzy Energy Management Strategy for Series Hybrid Electric Vehicle with Predictive Control and Durability Extension of the Battery. *2006 IEEE Conference on Electric and Hybrid Vehicles*, pages 1–5, dec 2006.
- [43] Amin Hajizadeh and Masoud Aliakbar Golkar. Intelligent power management strategy of hybrid distributed generation system. *International Journal of Electrical Power & Energy Systems*, 29 :783–795, 2007.
- [44] Frederick G. Harmon, Andrew a. Frank, and Sanjay S. Joshi. The control of a parallel hybrid-electric propulsion system for a small unmanned aerial vehicle using a CMAC neural network. *Neural Networks*, 18 :772–780, 2005.
- [45] Xiao Lin Harpreetsingh Banvait Sohel Anwar, Yaobin Chen. Plug-in Hybrid Electric Vehicle Energy Management System using Particle Swarm Optimization. *World Electric Vehicle Journal Vol. 3 - ISSN 2032-6653 - Â© 2009 AVERE*, 3 :11, 2009.

- [46] Rania Hassan and Babak Cohanin. A comparison of particle swarm optimization and the genetic algorithm. *1st AIAA multidisciplinary design optimization specialist conference*, pages 1–13, 2005.
- [47] S Haykin. *Neural networks-A comprehensive foundation*, 1994.
- [48] T Hofman and M Steinbuch. Rule-based equivalent fuel consumption minimization strategies for hybrid vehicles. *Proceedings of the . . .*, 2008.
- [49] J.N. Hooker. Optimal driving for single-vehicle fuel economy. *Transportation Research Part A : General*, 22(3) :183–201, 1988.
- [50] International Energy Agency IEA. Global EV Outlook 2017 : Two million and counting. *IEA Publications*, pages 1–71, 2017.
- [51] Advanced Intelligent and Mechatronics Proceedings. Optimisation of energy Flow Management in Hybrid Electric Vehicles via Genetic Algorithms. *Proceedings of the 2001 IEEE/ASME International Conference on Advanced Intelligent Mechatronics*, (July) :434–439, 2001.
- [52] A Ivanco, G Colin, Y Chamaillard, A Charlet, and P Higelin. Energy Management Strategies for a Pneumatic-Hybrid Engine Based on Sliding Window Pattern Recognition. (January 2010), 2014.
- [53] Damien Verry Jimmy Armoogum, Élisabeth Bouffard-Savary, Yann Caenen, Christine Couderc, Jérémy Courel, François Delisle, Philippe Duprat, Laurent Fouin, Dominique François, Marie-Odile Gascon, Dominique Godineau, Richard Grimal, Jean-Paul Hubert, Yan Le Gal, Josiane L. La mobilité des Français, panorama issu de l'enquête nationale transports et déplacements 2008. *La Revue du CGDD*, 2010.
- [54] L Johannesson, M Asbogard, and B Egardt. Assessing the potential of predictive control for hybrid vehicle powertrains using stochastic dynamic programming. *Intelligent Transportation Systems, 2005. Proceedings. 2005 IEEE*, pages 366–371, 2005.
- [55] S. Kermani, S. Delprat, T.M. Guerra, R. Trigui, and B. Jeanneret. Predictive energy management for hybrid vehicle. *Control Engineering Practice*, 20(4) :408–420, apr 2012.
- [56] Hamid Khayyam and Alireza Bab-Hadiashar. Adaptive intelligent energy management system of plug-in hybrid electric vehicle. *Energy*, 69 :319–335, 2014.
- [57] Joseph S. Krupa, Donna M. Rizzo, Margaret J. Eppstein, D. Brad Lanute, Diann E. Gaalema, Kiran Lakkaraju, and Christina E. Warrender. Analysis of a consumer survey on plug-in hybrid electric vehicles. *Transportation Research Part A : Policy and Practice*, 64 :14–31, 2014.
- [58] R.J. Kuo, Y.J. Syu, Zhen-Yao Chen, and F.C. Tien. Integration of particle swarm optimization and genetic algorithm for dynamic clustering. *Information Sciences*, 195 :124–140, 2012.
- [59] Antti Lajunen. Development of Energy Management Strategy for Plug-in Hybrid City Bus. *IEEE*, 2012.
- [60] James Larminie and John Lowry. *Electric Vehicle Technology Explained*. John Wiley & Sons, Ltd, Chichester, UK, aug 2012.
- [61] W LHOMME, P DELARUE, A BOUSCAYROL, and P BARRADE. La rem, formalisme multiphysique de commande de systèmes énergétiques, 2017.

- [62] Chun-Yan Li and Guo-Ping Liu. Optimal fuzzy power control and management of fuel cell/battery hybrid vehicles. *Journal of Power Sources*, 192(2) :525–533, 2009.
- [63] Kaibo Li, Alain Bouscayrol, Shumei Cui, and Shouliang Han. Energetic Macroscopic Representation and Inversion-Based Control of an Electrical Vehicle Using Modular Cascade Machines. *2016 IEEE Vehicle Power and Propulsion Conference, VPPC 2016 - Proceedings*, (1) :0–5, 2016.
- [64] Linhui Li, Haiyang Huang, Jing Lian, Baozhen Yao, Yafu Zhou, Jing Chang, and Ning Zheng. Research of Ant Colony Optimized Adaptive Control Strategy for Hybrid Electric Vehicle. 2014, 2014.
- [65] Chan-Chiao Lin, Peng Huei, and J.W. Grizzle. A stochastic control strategy for hybrid electric vehicles. *Proceedings of the American Control Conference*, pages 4710–4715, 2004.
- [66] Chan-chiao Lin, Huei Peng, Soonil Jeon, and Jang Moo Lee. Control of a Hybrid Electric Truck Based on Driving Pattern Recognition. *Proceedings of the 2002 Advanced Vehicle Control Conference, Hiroshima, Japan, (September)*, 2002.
- [67] Chris Manzie, Harry Watson, and Saman Halgamuge. Fuel economy improvements for urban driving : Hybrid vs. intelligent vehicles. *Transportation Research Part C : Emerging Technologies*, 15(1) :1–16, 2007.
- [68] T Markel, a Brooker, T Hendricks, V Johnson, K Kelly, B Kramer, M O'Keefe, S Sprik, and K Wipke. ADVISOR : a systems analysis tool for advanced vehicle modeling. *Journal of Power Sources*, 110(2) :255–266, aug 2002.
- [69] Ali Emadi Mehrdad Ehsani, Yimin Gao, Sebastien E. Gay. *Modern Electric, Hybrid Electric, and Fuel Cell Vehicles : Fundamentals, Theory, and Design*. 2004.
- [70] Felicitas Mensing, Eric Bideaux, Rochdi Trigui, Julien Ribet, and Bruno Jeanneret. Eco-driving : An economic or ecologic driving style ? *Transportation Research Part C : Emerging Technologies*, 38 :110–121, 2014.
- [71] Felicitas Mensing, Rochdi Trigui, and Eric Bideaux. Vehicle trajectory optimization for hybrid vehicles taking into account battery state-of-charge. *2012 IEEE Vehicle Power and Propulsion Conference*, pages 950–955, 2012.
- [72] Ayman Moawad, Gurhari Singh, Simeon Hagspiel, Mohamed Fellah, and Aymeric Rousseau. Impact of real world drive cycles on PHEV fuel efficiency and cost for different powertrain and battery characteristics. *World Electric Vehicle Journal*, 3, 2009.
- [73] Peter Mock, Jörg Kühlwein, Uwe Tietge, Vicente Franco, Anup Bandivadekar, and John German. The WLTP : How a new test procedure for cars will affect fuel consumption values in the EU. (October), 2014.
- [74] O.D. Momoh and M.O. Omoigui. An overview of hybrid electric vehicle technology. *2009 IEEE Vehicle Power and Propulsion Conference*, pages 1286–1292, sep 2009.
- [75] Morteza Montazeri-Gh, Amir Poursamad, and Babak Ghalichi. Application of genetic algorithm for optimization of control strategy in parallel hybrid electric vehicles. *Journal of the Franklin Institute*, 343(4-5) :420–435, 2006.
- [76] Jorge Moreno, Juan Dixon, and M. Ortúzar. Energy Management System for an Hybrid Electric Vehicle , Using Ultracapacitors and Neural Networks. *IEEE Transactions on Industrial Electronics*, 52(2) :614–623, 2006.

- [77] Yi Lu Murphey. Intelligent Vehicle Power Management : An Overview. In *Computational Intelligence in Automotive Applications SE - 10*, volume 190, pages 169–190. 2008.
- [78] Yi Murphey, Jungme Park, and Leonidas Kiliaris. Intelligent Hybrid Vehicle Power Control-Part II : Online Intelligent Energy Management. *Vehicular . . .*, 62(1) :69–79, 2013.
- [79] Cristian Musardo, Giorgio Rizzoni, Yann Guezennec, and Benedetto Staccia. A-ECMS : An Adaptive Algorithm for Hybrid Electric Vehicle Energy Management. *European Journal of Control*, 11(4-5) :509–524, jan 2005.
- [80] Ahmed Neffati, Mouloud Guemri, Stéphane Caux, and Maurice Fadel. Energy management strategies for multi source systems. *Electric Power Systems Research*, 102 :42–49, sep 2013.
- [81] Tobias Nüesch, Mu Wang, Pascal Isenegger, Christopher H. Onder, Rüdiger Steiner, Pedro Macri-Lassus, and Lino Guzzella. Optimal energy management for a diesel hybrid electric vehicle considering transient PM and quasi-static NOx emissions. *Control Engineering Practice*, 29 :266–276, 2014.
- [82] G.J. Offer, D. Howey, M. Contestabile, R. Clague, and N.P. Brandon. Comparative analysis of battery electric, hydrogen fuel cell and hybrid vehicles in a future sustainable road transport system. *Energy Policy*, 38(1) :24–29, jan 2010.
- [83] S. Onori and L. Serrao. On Adaptive-ECMS strategies for hybrid electric vehicles. *Les Rencontres Scientifiques d'IFP Energies nouvelles - Int. Scient. Conf. on hybrid and electric vehicles - RHEVE 2011*, (December) :1–7, 2011.
- [84] Aishwarya Panday and Hari Om Bansal. A Review of Optimal Energy Management Strategies for Hybrid Electric Vehicle. 2014, 2014.
- [85] G Pasaoglu, D Fiorello, A Martino, G Scarcella, A Alemanno, A Zubaryeva, and C Thiel. *Driving and parking patterns of European car drivers - a mobility survey*. 2012.
- [86] Laura V. Pérez, Guillermo R. Bossio, Diego Moitre, and Guillermo O. García. Optimization of power management in an hybrid electric vehicle using dynamic programming. *Mathematics and Computers in Simulation*, 73(1-4 SPEC. ISS.) :244–254, 2006.
- [87] Pierluigi Pisu, Codrin-gruie Cantemir, and Nicholas Dembski. Evaluation of power-train solutions for Future Tactical Truck Vehicle Systems. 1(614), 2006.
- [88] Amir Poursamad and Morteza Montazeri. Design of genetic-fuzzy control strategy for parallel hybrid electric vehicles. *Control Engineering Practice*, 16(7) :861–873, 2008.
- [89] B.K. Powell and T.E. Pilutti. A Range Extender Hybrid Electric Vehicle dynamic model. *Proceedings of 1994 33rd IEEE Conference on Decision and Control*, 3 :2736–2741, 1994.
- [90] Jinhuan Pu, Chenliang Yin, and Jianwu Zhang. Fuel optimal control of parallel hybrid electric vehicles. *Frontiers of Mechanical Engineering in China*, 3(3) :337–342, 2008.
- [91] C Quigley, R Mclaughlin, and Warwick Control. Advanced Microsystems for Automotive Applications 2011. pages 199–211, 2011.

- [92] Lawrence R. Rabiner. A tutorial on hidden Markov models and selected applications in speech recognition, 1989.
- [93] Anton Rassölkin. An Overview of Electrical Vehicle and Hybrid Electrical Vehicle Drives. In *13th International Symposium "Topical problems in the field of electrical and power engineering. Doctoral school of energy and geotechnology II"*, pages 76–80, 2013.
- [94] Alexandre Ravey, Benjamin Blunier, Srdjan Lukic, and Abdellatif Miraoui. Control strategy of fuel cell hybrid electric vehicle based on driving cycle recognition. *2012 IEEE Transportation Electrification Conference and Expo (ITEC)*, pages 1–5, 2012.
- [95] Route Recognition, Energy Management, and Plughybrid Electric Vehicles. Chalmers Publication Library Benefit of Route Recognition in Energy Management of Plug-in Hybrid Electric Vehicles. 2012.
- [96] Guizhou Ren, Guoqing Ma, and Ning Cong. Review of electrical energy storage system for vehicular applications. *Renewable and Sustainable Energy Reviews*, 41 :225–236, 2015.
- [97] G Ripaccioli, a Bemporad, F Assadian, and C Dextreit. Hybrid Modeling , Identification , and Predictive Control : An Application to Hybrid Electric Vehicle Energy Management. *Hybrid Systems : Computation and Control*, pages 321–335, 2009.
- [98] P. Rodatz, G. Paganelli, a. Sciarretta, and L. Guzzella. Optimal power management of an experimental fuel cell/supercapacitor-powered hybrid vehicle. *Control Engineering Practice*, 13(1) :41–53, jan 2005.
- [99] Aymeric Rousseau, Sylvain Pagerit, and David Wenzhong Gao. Plug-in Hybrid Electric Vehicle Control Strategy Parameter Optimization. *Journal of Asian Electric Vehicles*, 6 :1125–1133, 2008.
- [100] M.a Michelle Ruttly, L.a Lindsay Matthews, Jean Andrey, and Tania Del T.D.b Matto. Eco-driver training within the City of Calgary's municipal fleet : Monitoring the impact. *Transportation Research Part D : Transport and Environment*, 24 :44–51, 2013.
- [101] Philippe Schwoerer. Inde : Toutes les voitures vendues devront être électriques dès 2030, 2017.
- [102] A. Sciarretta and L. Guzzella. Control of hybrid electric vehicles. *Control Systems, IEEE*, 27(2) :60–70, 2007.
- [103] Julien Scordia. Systematic approach of the sizing optimization and the elaboration of energy management laws for an hybrid vehicle. In *Other*, 2004.
- [104] Lorenzo Serrao, S Onori, and G Rizzoni. A comparative analysis of energy management strategies for hybrid electric vehicles. *Journal of . . .*, 2011.
- [105] Caiying Shen, Peng Shan, and Tao Gao. A Comprehensive Overview of Hybrid Electric Vehicles. *International Journal of Vehicular Technology*, 2011 :1–7, 2011.
- [106] Carla Silva, Marc Ross, and Tiago Farias. Evaluation of energy consumption, emissions and cost of plug-in hybrid vehicles. *Energy Conversion and Management*, 50(7) :1635–1643, 2009.
- [107] Delphine Sinoquet, Gregory Rousseau, and Yohan Milhau. Design optimization and optimal control for hybrid vehicles. *Optimization and Engineering*, 12(1-2) :199–213, 2011.

- [108] S. N. Sivanandam, S. Sumathi, and S. N. Deepa. *Introduction to fuzzy logic using MATLAB*. Number 1. 2007.
- [109] Marco Sorrentino, Gianfranco Rizzo, and Ivan Arsie. Analysis of a rule-based control strategy for on-board energy management of series hybrid vehicles. *Control Engineering Practice*, 19(12) :1433–1441, 2011.
- [110] Fwenaelle Souffran, Laurence Miegerville, and Patrick Guerin. Simulation of Real-World Vehicle Missions Using a Stochastic Markov Model for Optimal Design Purposes. *Vehicular Power and Propulsion Conference*, (1), 2011.
- [111] Maria Staubach, Norbert Schebitz, Frank Köster, and Detlef Kuck. Evaluation of an eco-driving support system. *Transportation Research Part F : Traffic Psychology and Behaviour*, 27 :11–21, nov 2014.
- [112] Stephanie Stockar, Vincenzo Marano, Marcello Canova, Giorgio Rizzoni, and Lino Guzzella. Energy-optimal control of plug-in hybrid electric vehicles for real-world driving cycles. *IEEE Transactions on Vehicular Technology*, 60(7) :2949–2962, 2011.
- [113] Chao Sun, Scott Jason Moura, Xiaosong Hu, J Karl Hedrick, and Fengchun Sun. Management in Plug-in Hybrid Electric Vehicles. 23(3) :1075–1086, 2015.
- [114] Olle ; Lino Guzzella ; Patrik Soltic Sundstr. Optimal Hybridization in Two Parallel Hybrid Electric Vehicles using Dynamic Programming. *the 17th World Congress The International Federation of Automatic Control*, pages 4642–4647, 2008.
- [115] Olle Sundström and Lino Guzzella. A generic dynamic programming Matlab function. *Proceedings of the IEEE International Conference on Control Applications*, (7) :1625–1630, 2009.
- [116] T&E. Mind the Gap ! Why official car fuel economy figures don't match up to reality. page 47p, 2013.
- [117] Dušan Teodorović. Swarm intelligence systems for transportation engineering : Principles and applications. *Transportation Research Part C : Emerging Technologies*, 16(6) :651–667, 2008.
- [118] Dong Tingting and Z Fuquan. Design method and control optimization of an extended range electric vehicle. *Vehicle Power and ...*, 15(1), 2011.
- [119] Michael TORREGROSSA. Norvège : les véhicules électriques et hybrides ont représenté plus de 50 % des ventes en 2017, 2018.
- [120] Michael TORREGROSSA. Proposal for post-2020 co2 targets for cars and vans, 2018.
- [121] J.L. Torres, R. Gonzalez, A. Gimenez, and J. Lopez. Energy management strategy for plug-in hybrid electric vehicles. A comparative study. *Applied Energy*, 113 :816–824, 2014.
- [122] Cours N Traitement. Traitement d'images Particules isolées , protéines macromolécules , petits Digital images Digital images Sampling-1.
- [123] Laura Tribioli, Michele Barbieri, Roberto Capata, Enrico Sciubba, Elio Jannelli, and Gino Bella. A real time energy management strategy for plug-in hybrid electric vehicles based on optimal control theory. *Energy Procedia*, 45 :949–958, 2014.
- [124] UNFCCC. Conference of the Parties (COP). Paris Climate Change Conference-November 2015, COP 21. *Adoption of the Paris Agreement. Proposal by the President.*, 21932(December) :32, 2015.

- [125] Mahyar Vajedi, Maryyeh Chehrehsaz, and Nasser L Azad. Intelligent power management of plug-in hybrid electric vehicles , part II : real-time route based power management. *International Journal of Electric and Hybrid Vehicles*, 6(1) :68–86, 2014.
- [126] J. Van Mierlo, G. Maggetto, and Ph Lataire. Which energy source for road transport in the future ? A comparison of battery, hybrid and fuel cell vehicles. *Energy Conversion and Management*, 47(17) :2748–2760, 2006.
- [127] Rong-jong Wai, Shih-jie Jhung, Jun-jie Liaw, and Yung-ruei Chang. Intelligent Optimal Energy Management System for Hybrid Power Sources Including Fuel Cell and Battery. *IEEE Transaction on power electronics*, 28(7) :3231–3244, 2013.
- [128] Nicolas Watrin, Benjamin Blunier, and Abdellatif Miraoui. Review of adaptive systems for lithium batteries state-of-charge and state-of-health estimation. *2012 IEEE Transportation Electrification Conference and Expo, ITEC 2012*, (3), 2012.
- [129] Jong-Seon Won Jong-Seon Won and R. Langari. Intelligent energy management agent for a parallel hybrid vehicle. *Proceedings of the 2003 American Control Conference, 2003.*, 3 :2560–2565, 2003.
- [130] Changxu Wu, Guozhen Zhao, and Bo Ou. A fuel economy optimization system with applications in vehicles with human drivers and autonomous vehicles. *Transportation Research Part D : Transport and Environment*, 16(7) :515–524, 2011.
- [131] Guoyuan Wu, Kanok Boriboonsomsin, and Matthew Barth. Development and Evaluation of Intelligent Energy Management Strategies for Plug-in Hybrid Electric Vehicles Development and Evaluation of Intelligent Energy Management Strategies for Plug-in Hybrid Electric Vehicles. (January) :1–19, 2012.
- [132] Xiaolan Wu, Binggang Cao, Jianping Wen, and Yansheng Bian. Particle swarm optimization for plug-in hybrid electric vehicle control strategy parameter. *2008 IEEE Vehicle Power and Propulsion Conference*, pages 1–5, 2008.
- [133] Mark S. Young, Stewart A. Birrell, and Neville A. Stanton. Safe driving in a green world : A review of driver performance benchmarks and technologies to support 'smart' driving. *Applied Ergonomics*, 42(4) :533–539, 2011.
- [134] Zhe Yu, Shanjun Li, and Lang Tong. Market Dynamics and Indirect Network Effects in Electric Vehicle Diffusion. (Shanjun Li), 2015.
- [135] Chen Zhang Chen Zhang and A. Vahidi. Real-time optimal control of plug-in hybrid vehicles with trip preview. *American Control Conference (ACC), 2010*, pages 6917–6922, 2010.
- [136] Mengyang Zhang. HEV powertrain fundamentals. In *2011 IEEE Vehicle Power and Propulsion Conference, VPPC 2011*, 2011.
- [137] Pei Zhang, Fuwu Yan, and Changqing Du. A comprehensive analysis of energy management strategies for hybrid electric vehicles based on bibliometrics. *Renewable and Sustainable Energy Reviews*, 48(205) :88–104, 2015.

Résumé :

L'objectif principal de ce travail est de développer une stratégie de gestion optimale afin d'améliorer l'efficacité énergétique des véhicules hybrides. Ces travaux comportent une partie analyse expérimentale de la mobilité, une partie modélisation numérique et une partie optimisation de la stratégie de gestion énergétique. L'étude de la mobilité a permis de mettre en avant et de quantifier la prédictibilité des trajets, dus à une forte mobilité contrainte. La modélisation dynamique du véhicule nécessaire à l'étude de stratégie a été réalisée par Représentation Énergétique Macroscopique (REM) qui est une bonne méthode pour ce type d'étude. La stratégie proposée est basée sur le contrôle prédictif (MPC), résolu par une méthode de Programmation Quadratique, et mis en place en s'appuyant sur la prédiction de cycle issu de l'étude expérimentale. Les perspectives d'améliorations de ces travaux se situent au niveau de la consolidation de la base de données, et du niveau de modélisation de la batterie (impact de la thermique et du vieillissement) et du moteur thermique (prise en compte des polluants).

Mots-clés : Véhicule électrique hybride, REM, mobilité, contrôle optimal, prédiction de cycle, efficacité énergétique

Abstract:

The main objective of this work is to develop an optimal management strategy to improve energetic efficiency of hybrid electric vehicle. This work is composed by a mobility experimental analysis part, a numerical modelization part and an optimization part of the energy management strategy. The study of mobility allow to highlight and quantify the predictability of trips, due to a constraint mobility. The dynamic modelling of the vehicle which is necessary to study performance of strategies, was realized by Energetic Macroscopic Representation (EMR) which is a good method in this case. The proposed strategy is based on the predictive control (MPC), solve by a method of Programming Quadratic, and set up resting on the cycle prediction determined from the experimental study. The perspectives of improvements of these work are consolidation of the database, and improvement of the battery modelling (including thermal and ageing effects) and of the thermal engine (taken into account by some pollutants).

Keywords: Hybrid Electric Vehicle, EMR, mobility, optimal control, cycle prediction, energetic efficiency

