



**BADJI MOKHTAR -ANNABA
UNIVERSITY
UNIVERSITE BADJI MOKHTAR
ANNABA**

وزارة التعليم العالي والبحث العلمي

**جامعة باجي مختار
- عنابة -**

Faculté des Sciences de l'ingéniorat

Année : 2018

Département d'électronique

THÈSE

Présenté en vue de l'obtention du diplôme de Doctorat 3ème Cycle

ETUDE DE STRATEGIES DE COMMANDE POUR VEHICULES HYBRIDES

Option

AUTOMATIQUE ET SIGNAUX

Par

Moatez Billah HARIDA

DIRECTEUR DE THÈSE : Mohamed Mourad LAFIFI M.C.A U.B.M. ANNABA

Devant le jury

PRESIDENT : Hadj Ahmed ABBASSI

Prof U.B.M. ANNABA

EXAMINATEUR : Mohamed FEZARI

Prof U.B.M. ANNABA

EXAMINATEUR : Abdelkrim MOUSSAOUI

Prof U. GUELMA

EXAMINATEUR : Abderrazak LACHOURI

Prof U. SKIKDA

INVITE : Brahim BOULEBTATECHE

M.C.B U.B.M. ANNABA

ملخص

هذه الدراسة تركز بشكل خاص علي التحسين والتحكم في المحرك الخاص بالسيارات المهجنة المتواليّة-الموازية (HEV). هذا النوع من التهجين مثيرة للاهتمام من حيث الأهداف ولكن معقدة على مستوى تحسين الأداء. لهذا فإننا بحاجة إلى دقة أكثر صرامة على تقريب نموذج محرك الاحتراق ، اعتمدنا في اختياراتنا علي نمودجين, النموذج الخطي الذي تحصلنا عليه باستعمال طريقة التعرف SUBSPACE ونمودج اللاخطي الذي تحصلنا عليه باستعمال طريقة تعليم الشبكات العصبية. وسيتم دمج هذين النمودجين في التحكم التنبؤي الذي أستعمل كمثبت لسرعة محرك الاحتراق, وسيتم تطبيق المزيد من التحسينات على مستوى وحدة تسيير الطاقة. وأخيرا، تم إجراء دراسة مقارنة بين العديد من مثبتي السرعة لمحرك الاحتراق وعدة طرق لتسيير الطاقة، مما أدى الي الحصول علي أفضل استراتيجية التحكم الشاملة تتضمن أفضل التقنيات و الأداء من حيث استهلاك الوقود لمحرك الاحتراق وخفض الانبعاثات السامة و المحافظة علي نظافة البيئة.

الكلمات المفتاحية: السيارة المهجنة - النموذج الخطي - النموذج اللاخطي - محرك الديزل - نموذج محرك الاحتراق - محاكي HEV - التحكم التنبؤي - استراتيجية التحكم.

Abstract

The main purpose of this work is the optimization and control of Series-Parallel Hybrid Vehicles (HEV) engines. This type of hybridization is interesting to achieve, but complex when the performance optimization is involved. The latter requires that the approximation of the model must be done with big care. We have made two choices of the engine model. The first proposed model is a linear type obtained by SUBSPACE identification method, and the second choice is a nonlinear model obtained by training neural networks. These two models will be integrated into the control structures. The predictive control is designed as an engine speed regulator; further improvements will be applied at the level of the power management module. Finally, a comparative study is made between several engine speed regulators and several modes of the power management; resulting in a global control strategy which includes the best techniques that may improve the performance in terms of the engine fuel consumption; hence reducing toxic emissions and maintaining a clean environment.

Key words: *Hybrid vehicle - Nonlinear model - Linear model - Diesel engine - Engine modelling - HEV simulator - Predictive control - Control Strategy.*

Résumé

Cette étude porte essentiellement sur l'optimisation et la commande du moteur à combustion conçu pour les véhicules hybrides séries-parallèles, ce type d'hybridation est intéressant au niveau des objectifs mais complexe au niveau de l'optimisation des performances. Pour cela on impose une rigueur des plus sévères quant à l'approximation du modèle du moteur à combustion. Notre choix s'est porté sur deux types de modèles, un modèle linéaire obtenu par la méthode d'identification des systèmes appelé 'SUBSPACE' et un modèle non linéaire obtenu par l'apprentissage des réseaux neuronaux. Ces deux modèles vont être intégrés dans les structures de commande. La commande prédictive est conçue comme régulateur de vitesse du moteur à combustion, en outre des améliorations seront appliquées au niveau du module de gestion d'énergie. Enfin une étude comparative est faite entre plusieurs régulateurs de vitesse du moteur thermique et plusieurs modes de gestion d'énergie, il en résulte une stratégie de commande globale intégrant les meilleurs techniques et ce pour obtenir les performances en terme de consommation du carburant du moteur à combustion et par-delà baisser les émissions toxique et rendre l'environnement plus propre.

Mots clés: *véhicule Hybride - Modèle non linéaire - Modèle linéaire - Moteur diesel - Modélisation du moteur - Simulateur HEV - Commande prédictive - Stratégie de commande.*

Dédicaces

*J*e dédie ce modeste travail à :

- ✦ *Ma grand-mère.*
- ✦ *Mes très chers parents.*
- ✦ *Mes frères.*
- ✦ *Mes enseignants et mes chers amis.*
- ✦ *Ainsi qu'à tous ceux qui me sont chers.*
- ✦ *Sans oublier tous les membres de la famille qui avance.*

HARIDA.MOATEZ-BILLAH

Remerciement

Je tiens premièrement à se prosterner devant Allah le tout puissant de m'avoir donné le courage, l'abnégation et la patience pour avoir accomplie ce travail.

J'adresse tout d'abord mes sincères remerciements à Monsieur Mohamed Mourad LAFIFI mon directeur de thèse, Maître de conférences 'A' à l'Université d'Annaba et à Monsieur Brahim BOULEBTATECHE mon co-directeur de thèse, Maître de conférences 'B' à l'Université d'Annaba pour la confiance qu'ils m'ont témoignée. Leur expérience de recherche, leurs conseils, leurs encouragements qui m'ont été très précieux et m'ont permis de bien mener mon travail.

Je tiens à exprimer ma profonde gratitude à Monsieur Hadj Ahmed ABBASSI Professeur à l'Université d'Annaba d'avoir accepté de présider mon jury de thèse.

Je tiens également à remercier Messieurs Abdelkrim MOUSSAOUI, Professeur à l'Université de Guelma, Abderrazak LACHOURI, Professeur à l'Université de Skikda et Mohamed FEZARI, Professeur à l'Université d'Annaba d'avoir accepté d'examiner mon travail.

Je tiens à remercier le laboratoire LASA et ces membres ainsi que les enseignants et mes collègues du département d'électronique pour leur soutien durant toutes ces années.

HARIDA.MOATEZ-BILLAH

Liste des Tableaux

<i>Tableau 1.1</i>	<i>Configuration système globale requise.....</i>	<i>12</i>
<i>Tableau 1.2</i>	<i>Configuration système requise pour le moteur à combustion.....</i>	<i>14</i>
<i>Tableau 1.3</i>	<i>Les paramètres optimaux pour les régulateurs de vitesse PI.....</i>	<i>18</i>
<i>Tableau 2.1</i>	<i>Grandeurs de la représentation de l'espace d'état.....</i>	<i>24</i>
<i>Tableau 3.1</i>	<i>Les paramètres optimaux pour le régulateur de vitesse MPC.....</i>	<i>46</i>
<i>Tableau 3.2</i>	<i>Les contraintes appliquées sur la commande MPC.....</i>	<i>47</i>
<i>Tableau 4.1</i>	<i>Les paramètres optimaux pour le régulateur de vitesse NNPC.....</i>	<i>60</i>
<i>Tableau 4.2</i>	<i>Les contraintes appliquées sur la commande NNPC.....</i>	<i>61</i>
<i>Tableau 5.1</i>	<i>Les règles d'activation ou désactivation des régulateurs de vitesses.....</i>	<i>68</i>
<i>Tableau 5.2</i>	<i>Économie de carburant obtenus durant le test dans cycle NEDC.....</i>	<i>79</i>

Liste des Figures

<i>Figure 1.1</i> Architecture hybride série.....	8
<i>Figure 1.2</i> Architecture hybride parallèle.....	10
<i>Figure 1.3</i> Architecture série-parallèle.....	11
<i>Figure 1.4</i> Le diagramme de simulation de véhicule hybride série-parallèle.....	12
<i>Figure 1.5</i> Bloc diagramme du moteur à combustion interne.....	13
<i>Figure 1.6</i> Bloc train épicycloïdal.....	14
<i>Figure 1.7</i> Diagramme du train épicycloïdal.....	15
<i>Figure 1.8</i> Bloc servomoteur.....	15
<i>Figure 1.9</i> Bloc de commande.....	16
<i>Figure 1.10</i> Régulateur de vitesse du moteur à combustion.....	17
<i>Figure 1.11</i> Régulateur de vitesse de la génératrice.....	17
<i>Figure 1.12</i> Régulateur de vitesse du moteur électrique.....	18
<i>Figure 1.13</i> Mode logique modélisée avec Stateflow®.....	20
<i>Figure 2.1</i> Schéma simplifié du moteur diesel.....	24
<i>Figure 2.2</i> Schéma de simulation de l'estimation des paramètres du modèle du moteur diesel.....	27
<i>Figure 2.3</i> Signal d'entrée-sortie du moteur à combustion.....	28
<i>Figure 2.4</i> Le modèle neuronal NARX.....	28
<i>Figure 2.5</i> Rendement d'apprentissage du réseau neuronal.....	29
<i>Figure 2.6</i> Régression d'apprentissage du réseau neuronal.....	30

<i>Figure 2.7</i> Le modèle neuronal connecté au moteur à combustion dans un schéma de simulation du véhicule hybride.....	31
<i>Figure 2.8</i> Régulateur de vitesse du moteur diesel.....	32
<i>Figure 2.9</i> Courbes d'accélération avant l'introduction de la contrainte.....	33
<i>Figure 2.10</i> Courbes d'accélération après l'introduction de la contrainte.....	33
<i>Figure 2.11</i> Vitesse du moteur à combustion réelle (tr /min) et vitesse du moteur à combustion modélisée (tr /min) avec perturbation (cycle 1).....	34
<i>Figure 2.12</i> Vitesse du moteur à combustion réelle (tr /min) et vitesse du moteur à combustion modélisée (tr /min) avec perturbation (cycle 2).....	35
<i>Figure 2.13</i> Vitesse du moteur à combustion réelle (tr /min) et vitesse du moteur à combustion modélisée (tr /min) avec perturbation (cycle 3).....	35
<i>Figure 2.14</i> La différence entre la vitesse du moteur diesel réelle et la vitesse du modèle neuronal avec perturbation.....	36
<i>Figure 2.15</i> Modèle neuronal connecté au moteur à combustion dans le diagramme de simulation du H ₂ EV avec atténuation des perturbations.....	37
<i>Figure 2.16</i> La différence entre la vitesse du moteur à combustion réelle et la vitesse du modèle neuronal avec réduction de perturbation.....	38
<i>Figure 3.1</i> Schéma de principe de la stratégie de la commande prédictive.....	45
<i>Figure 3.2</i> Régulateur de vitesse du moteur à combustion à base de MPC.....	46
<i>Figure 3.3</i> Le contrôleur MPC testé sur le cycle urbain (UDC).....	48
<i>Figure 3.4</i> Processus d'apprentissage du réseau neuronal.....	49
<i>Figure 4.1</i> Processus d'apprentissage du réseau neuronal.....	53
<i>Figure 4.2</i> La structure du réseau neuronal du système.....	53
<i>Figure 4.3</i> Modèle neuronal NARX.....	54
<i>Figure 4.4</i> Performance d'apprentissage du réseau neuronal.....	55

<i>Figure 4.5</i> Régression d'apprentissage du réseau neuronal.....	56
<i>Figure 4.6</i> Données de validation de la commande prédictive à base de modèle neuronal...57	
<i>Figure 4.7</i> Schéma fonctionnel de la commande prédictive à base de modèle neuronal.....	59
<i>Figure 4.8</i> Régulateur de vitesse du moteur à combustion à base de NNPC.....	60
<i>Figure 4.9</i> Le contrôleur NNPC testé sur cycle urbain (UDC).....	62
<i>Figure 4.10</i> Le contrôleur NNPC testé sur le cycle extra-urbain (EUDC).....	63
<i>Figure 5.1</i> La gestion d'énergie améliorée.....	67
<i>Figure 5.2</i> Résultats de simulation obtenus à l'aide du régulateur de vitesse PI du moteur à combustion testé sur le cycle NEDC.....	69
<i>Figure 5.3</i> Résultats de simulation obtenus à l'aide du régulateur de vitesse MPC du moteur à combustion testé sur le cycle NEDC.....	70
<i>Figure 5.4</i> Résultats de simulation obtenus à l'aide du régulateur de vitesse NNPC du moteur à combustion testé sur le cycle NEDC.....	71
<i>Figure 5.5</i> Les signaux d'entrées du mode logique.....	73
<i>Figure 5.6</i> Les signaux de sorties du mode logique.....	74
<i>Figure 5.7</i> Résultats de simulation obtenus à l'aide du régulateur de vitesse PI du moteur à combustion et le mode logique testé sur le cycle NEDC.....	75
<i>Figure 5.8</i> Les signaux d'entrées du mode logique amélioré.....	76
<i>Figure 5.9</i> Les signaux de sorties du mode logique amélioré.....	77
<i>Figure 5.10</i> Résultats de simulation obtenus à l'aide du régulateur de vitesse NNPC du moteur à combustion et le mode logique améliorée testé sur le cycle NEDC.....	78

Nomenclature

Acronyme

PID	Proportional Integral Derivative
LQR	Linear Quadratic Regulator
HEV	Hybrid Electrical Vehicle
HEVMBFS	Hybrid Electrical Vehicle Model Balances Fidelity and Speed
NEDC	New European Driving Cycle
UDC	Urban Driving Cycle
EUDC	Extra-Urban Driving Cycle
MPC	Model Predictive Control
EPSAC	Extended Prediction Self-Adaptive Control
GPC	Generalized Predictive Control
UPC	Unified Predictive Control
NNPC	Neural Network Predictive Control
MLP	Multilayer Perceptron
NARX	Nonlinear Autoregressive Neural Network With External Input
MSE	Mean Squared Error
VEH	Véhicule Électrique Hybride

Symboles

Symbole	Description
NO _x	Oxyde d'azote
X _{egr}	Taux de recirculation du gaz d'échappement
m _f	Débit d'injection
x _{vgt}	Variation de la géométrie de la turbine
M _{load}	Moment de charge
n	Vitesse du vilebrequin
P _{man}	Pression du collecteur d'admission
m _{ff}	Débit du film d'injection
P _c	Puissance du compresseur
P _{ex}	Pression du collecteur d'échappement

T_{man}	Température du collecteur d'admission
T_{exo}	Température du collecteur d'échappement
u_k, y_k	Les mesures à l'instant k
x_k	Vecteur d'état du processus à un instant discret k
v_k	Bruit de mesure
w_k	Bruit de processus
A	La matrice du système
B	La matrice d'entrée
C	La matrice de sortie
D	La matrice d'application directe des entrées
Q, S, R	Les matrices de covariance des séquences de bruit w_k, v_k
$Q(ny - by - ny), R_{uu},$ $R_{\Delta u}(nu - by - nu)$	Les matrices de pondération semi-définie positive
S_y	La matrice diagonale de la sortie du système
S_u	La matrice diagonale de la grandeur d'entrée
$r(k + 1 k), n_y$	Valeur de référence de sortie système à l'ième phase d'horizon de prédiction
$y(k + 1 k), n_y$	Sortie système à l'ième phase d'horizon de prédiction
z_k	Décision de la programmation quadratique
$u_{\text{target}}(k + i k), n_u$	Valeurs de référence correspondant à $u(k + i k)$
N_1	L'horizon minimal de prédiction
N_2	L'horizon maximal de prédiction
N_u	L'horizon de prédiction sur la commande
U_{min}	La valeur de commande minimale
U_{max}	La valeur de commande maximale
Y_{min}	La valeur de sortie minimale
Y_{max}	La valeur de sortie maximale
y_r	La réponse désirée
y_m	La réponse du modèle neuronal

Sommaire

Introduction générale

Introduction générale	2
Organisation de la thèse.....	3

1. Chapitre 1 :

Structure des véhicules hybrides et simulateur.

1.1. Introduction	6
1.2. Différentes types d'architectures de véhicules hybrides	7
1.2.1. Architecture hybride série	8
1.2.2. Architecture hybride parallèle	9
1.2.3. Architecture série-parallèle	10
1.3. Le modèle du véhicule hybride	11
1.3.1. Moteur à combustion	13
1.3.2. Train épicycloïdal	14
1.3.3. Servomoteur	15
1.3.4. Bloc de commande	16
1.3.5. Gestion d'énergie	19
1.3.6. Mode logique	19
1.4. Conclusion	20

2. Chapitre 2 :

Modélisation du moteur diesel.

2.1. Introduction	23
2.2. Le modèle physique	23
2.3. Le modèle neuronal	26
2.4. Résultats de la simulation	31
2.5. Conclusion	38

3. Chapitre 3 :

La commande prédictive à base de modèle linéaire.

3.1. Introduction	41
3.2. La méthode SUBSPACE	41
3.3. La commande prédictive	43
3.4. Régulateur de vitesse	46
3.5. Résultats de la simulation	48
3.6. Conclusion	50

4. Chapitre 4 :**La commande prédictive à base de modèle neuronal.**

4.1. Introduction	52
4.2. Modèle neuronal	52
4.3. La commande prédictive	58
4.4. Régulateur de vitesse	59
4.5. Résultats de la simulation	61
4.6. Conclusion	64

5. Chapitre 5 :**Gestion d'énergie améliorée et l'étude comparative.**

5.1. Introduction	66
5.2. Gestion d'énergie améliorée	66
5.3. Résultats de l'étude de comparaison	69
5.3.1 Comparaison avec le mode logique désactivé.....	69
5.3.2 Comparaison avec le mode logique activé.....	72
5.4. Conclusion	80

Conclusion et perspectives

Conclusion	82
Perspectives	83

Bibliographie

Bibliographie	85
---------------------	----

Introduction générale

Introduction générale2

Organisation de la thèse.....3

Introduction générale

En 1834, la première voiture électrique, un tricycle, a été construite par Thomas Davenport. Le premier véhicule roulant au-dessus de la barrière de 100 km/h était également une voiture électrique, porte le nom de "Jamais Contente" en anglais "Never Satisfied", qui a été conduit par Camille Jenatzy en 1899. Avec l'amélioration considérable dans les véhicules traditionnels comportant un moteur à combustion, la voiture électrique a presque disparu de la scène dans les années 30. La crise énergétique et le manque de pétrole dans les années 70 à provoquer la réapparition des voitures électriques. La reprise réelle des voitures électriques était due à la préoccupation croissante concernant la conservation de l'énergie fossile et la protection de l'environnement dans le monde entier durant les années 90. À savoir, les véhicules électriques offrent un rendement énergétique élevé, permettent la diversification des ressources énergétiques, assurent l'égalisation de la charge des systèmes de puissance, à zéro émission et fonctionnent silencieusement. Cependant, il existe deux principaux obstacles à la commercialisation des véhicules électriques : l'autonomie réduite et le coût initial élevé (Chan, 1993; Chau and Wong, 2001). L'avènement du véhicule hybride (VEH), constitué de deux moteurs le premier à combustion et le second électrique, a été introduite comme une solution provisoire avant la mise en œuvre satisfaisante des véhicules électriques et ce après une percée technologique dans l'utilisation optimale des sources d'énergie dans les véhicules électriques (Wakefield, 1998), Les avantages bien déterminés du véhicule électrique hybride (VEH) sont d'étendre considérablement la gamme de véhicules d'origine de deux à quatre fois et d'offrir un ravitaillement rapide en essence liquide ou diesel. La mise à niveau de cette transformation est qu'elle exige seulement peu de changements dans l'infrastructure d'approvisionnement énergétique. Les principaux inconvénients du VEH sont la perte du concept d'émission zéro et

la complexité accrue dans leurs conception. Cependant, Le véhicule électrique hybride (VEH) est nettement moins polluant et consomme moins de carburant que la voiture traditionnelle, tout en conservant les mêmes conditions. Ces avantages sont dus au fait que le moteur thermique du véhicule électrique hybride (VEH) peut toujours fonctionner dans son mode le plus efficace, produisant de faibles émissions et une faible consommation de carburant. En outre, le véhicule électrique hybride (VEH) a la possibilité de fonctionner comme un véhicule électrique dans la zone d'émission zéro. Il devient un consensus que le véhicule électrique hybride n'est pas seulement une solution provisoire pour la mise en œuvre de véhicules zéro émission, mais aussi une solution pratique pour la commercialisation de véhicules à faibles émissions.

Organisation de la thèse

Cette thèse regroupe cinq chapitres, qui vont de la structure des véhicules hybrides et simulateur à la gestion d'énergie améliorée et l'étude comparative.

Le premier chapitre porte sur la structure des véhicules hybrides et simulateur. Une présentation des différents types d'architectures de véhicules hybrides, une description du simulateur qui contient un modèle du véhicule hybride série-parallèle et les principales composantes de ce dernier ont été détaillés, ainsi que le régulateur de vitesse classique du moteur à combustion et du mode logique.

Le deuxième chapitre porte sur la modélisation du moteur diesel par le modèle neuronal, plusieurs tests ont été faits afin de prouver la robustesse de ce modèle. L'implémentation et la simulation de modèle neuronal est réalisée dans l'environnement Matlab/Simulink.

Le troisième chapitre aborde la commande prédictive à base de modèle linéaire, une description de la méthode SUBSPACE est faite. Le modèle linéaire obtenu par la méthode SUBSPACE est utilisé par la commande prédictive afin de contrôler la vitesse du moteur à combustion. L'implémentation et la simulation est faite dans l'environnement Matlab/Simulink.

Le quatrième chapitre aborde la commande prédictive à base de modèle neuronal, une description détaillée sur la méthode utilisée afin d'obtenir un modèle neuronal. Ensuite, Le modèle neuronal est utilisé par la commande prédictive afin de contrôler le régime du moteur thermique. La simulation de l'implémentation est réalisée dans l'environnement Matlab/Simulink.

Le dernier chapitre porte sur la gestion d'énergie améliorée et l'étude comparative, une partie de ce chapitre a été consacrée pour l'amélioration de la gestion d'énergie, une seconde partie pour l'étude comparative entre les nouvelles méthodes et stratégies réalisées ainsi que les méthodes et stratégies existantes.

Pour clôturer ce manuscrit, une conclusion générale est faite à la lumière des résultats obtenus aussi nous avons dégagé des perspectives prometteuses suite à ce travail de recherche.

CHAPITRE 1

Structure des véhicules hybrides et simulateur

1.1. Introduction	6
1.2. Différentes types d'architectures de véhicules hybrides	7
1.2.1. Architecture hybride série	8
1.2.2. Architecture hybride parallèle	9
1.2.3. Architecture série-parallèle	10
1.3. Le modèle du véhicule hybride	11
1.3.1. Moteur à combustion	13
1.3.2. Train épicycloïdal	14
1.3.3. Servomoteur	15
1.3.4. Bloc de commande	16
1.3.5. Gestion d'énergie	19
1.3.6. Mode logique	19
1.4. Conclusion.....	20

1.1 Introduction

Le but de cette étude est d'améliorer les performances du véhicule hybride en réduisant la consommation d'énergie. De nombreux chercheurs ont appliqué les outils de commande classiques pour exploiter le potentiel d'économie de carburant, tels que les contrôleurs PID (Proportional Integral Derivative) et LQR (Linear Quadratic Regulator). Par exemple, le contrôleur de vitesse du moteur utilisé dans le simulateur "Hybrid Electrical Vehicle Model Balances Fidelity and Speed (HEVMBFS)" est un contrôleur PI. Ce dernier produit des efforts inutiles qui peuvent provoquer des accélérations intempestives du moteur; cela peut fortement nuire à la performance du moteur dans le long terme (Radhi and Hussien, 2013), quant au contrôleur LQR il n'a pas été testé sur le nouveau cycle européen de conduite (New European Driving Cycle (NEDC)). Outre cela les contrôleurs PID et LQR ne permettent pas d'anticiper sur les événements futurs et de prendre des mesures de contrôle en conséquence, par opposition à la commande prédictive (Model Predictive Control (MPC)) qui le permet (Harida et al., 2015). Dans ce contexte un grand nombre d'algorithmes de mise en œuvre ont été présentés dans la littérature citant, par exemple, la commande auto-adaptative à prédiction étendue (Extended Prediction Self-Adaptive Control (EPSAC)) (De Keyser and Van Cauwenberghe, 1985), la commande prédictive généralisé (Generalized Predictive Control (GPC)) (Clarke et al., 1987) et la commande prédictive unifiée (Unified Predictive Control (UPC)) (Soeterboek, 1992). La plupart de ces algorithmes de commande utilisent un modèle de processus explicite pour prédire le comportement futur d'un système, pour cette raison l'expression Model Predictive Control (MPC) est souvent utilisée. De nombreuses recherches ont introduit le contrôleur MPC, mais ce dernier a de nombreux obstacles dans le cas des systèmes non

linéaires car, la plupart des algorithmes MPC sont basés sur un modèle linéaire du processus. Pour surmonter la faiblesse de ces méthodes, nous utilisons la commande prédictive à base de réseau neuronal (Neural Network Predictive Controller (NNPC)) (Harida et al., 2015). Un grand nombre de commandes basés sur des réseaux neuronaux ont été présentés dans la littérature (Chen et al., 1990; Liu et al. 1998). Le contrôleur NNPC élimine les obstacles les plus significatifs pour la commande MPC non linéaire en développant un modèle non linéaire. Le contrôleur NNPC sera testé sur le nouveau cycle européen de conduite (New European Driving Cycle (NEDC)), en maintenant le niveau de puissance nécessaire pour une conduite confortable du véhicule hybride d'une part, d'autre part l'élimination des efforts inutiles produits par les contrôleurs classiques et l'optimisation de la consommation d'énergie. Enfin, pour que le contrôleur soit établi pour atteindre un niveau de performance appréciable, il sera nécessaire d'améliorer la gestion de l'énergie afin d'obtenir le niveau de consommation le plus bas possible, ainsi réduire les émissions NOx nuisible à l'environnement.

1.2 Différentes types d'architectures de véhicules hybrides

Contrairement aux voitures traditionnelles qui roulent à l'essence ou au diesel, la voiture hybride fonctionne avec deux moteurs: thermique et électrique. Elle fait donc appel à deux stockages d'énergie distincte: stockage d'énergie électrique (batterie) et stockage d'énergie fossile (réservoir de carburant). La voiture hybride est également une voiture écologique qui a pour objectif de limiter les émissions polluantes afin de contribuer à la protection de notre environnement (Martinez et al., 2012). On distingue trois

grandes architectures: l'architecture série, l'architecture parallèle et l'architecture série-parallèle.

1.2.1 Architecture hybride série

La configuration générale de ce système est composée d'un moteur thermique, un moteur électrique, une génératrice, un réservoir de carburant, une batterie, et un module de commande de l'alimentation (inverseur / convertisseur). Voir la présentation sur la figure 1.1. La motricité des roues est dédiée au moteur électrique quant au moteur thermique son rôle est de recharger la batterie à travers la génératrice. Si une grande batterie est utilisée, le véhicule sera plus électrique et le moteur à combustion aura une fréquence moindre de fonctionnement, de ce fait on arrive à une configuration proche d'un véhicule tout électrique (Nordlund, 2005; Xiaolai, 2006).




Figure 1.1: Architecture hybride série.

On note certains avantages et inconvénients de l'architecture hybride série qui sont les suivants :

Les avantages :

- Le moteur à combustion et le moteur de traction électrique peuvent être positionnés dans le véhicule ce qui permet de nouvelles dispositions de véhicules.
- Commande du moteur à combustion est optimale.
- Le moteur à combustion n'a pas besoin d'être dimensionné pour la puissance maximale.

Les inconvénients :

- Le système d'entraînement électrique doit être dimensionné pour une puissance maximale.
- Plusieurs étapes de conversions énergétiques, entraînent plus de pertes.

1.2.2 Architecture hybride parallèle

La configuration générale de ce système est composée de deux moteurs thermique et électrique, un réservoir de carburant, une batterie, et un module de commande de l'alimentation (inverseur / convertisseur). Ce système permet de sélectionner le moteur soit électrique soit thermique ou les deux ensemble. Lors des phases de freinage ou de décélération, le moteur électrique se transforme en générateur, récupère une partie de l'énergie cinétique et recharge la batterie. L'architecture générale de la technologie hybride parallèle est schématisée par la figure 1.2 (Kermani, 2009; Bernardinis, 2000; Sigmund et al., 2014).




Figure 1.2: Architecture hybride parallèle.

L'un des avantages de ce type de structure par rapport à la structure hybride série est un meilleur rendement global pour les demandes en puissances importantes. La complexité de la répartition des couples des deux moteurs et la boîte de vitesses sont les points faibles de cette architecture.

1.2.3 Architecture série-parallèle

Le système série-parallèle (figure 1.3) est composé d'un moteur électrique, un moteur thermique, une génératrice, un réservoir de carburant, une batterie, et un module de commande de l'alimentation (inverseur/convertisseur). La chaîne de traction de type "série-parallèle" est une combinaison entre une chaîne de traction série et une chaîne de traction parallèle (Miller et al., 2005). En phase de freinage, les deux machines électriques reconvertissent de l'énergie cinétique en énergie électrique dont une petite quantité est stockée dans la batterie (Béranger et al., 2009).




Figure 1.3: Architecture série-parallèle.

Cette structure "série-parallèle" combine les avantages de la structure série et ceux de la structure parallèle. Ce système est en effet caractérisé par la possibilité de fonctionner en hybride série et hybride parallèle, donc un fonctionnement série en basse vitesse et parallèle pour les puissances élevées. La transmission mécanique et la commande sont très complexes car pour un point de fonctionnement, il existe une multitude de solutions pour répartir le couple entre les deux moteurs. La figure 1.3 schématise le fonctionnement d'un hybride combiné (Škugor et al., 2012; Rousseau, 2008; Grammatico et al., 2010).

1.3 Le modèle du véhicule hybride

Le simulateur présenté dans la figure 1.4 nommé "Hybrid Electrical Vehicle Model Balance Fidelity and Speed (HEVMBFS)", contient un modèle de véhicule hybride série-parallèle, construit en utilisant les outils SimElectronics, SimDriveline, Simscape et SimPowerSystems, de Matlab

(Panagiotidis et al., 2000). Ce simulateur est téléchargeable gratuitement depuis le site officiel de Matlab.




Figure 1.4: Le diagramme de simulation de véhicule hybride série-parallèle.

Les caractéristiques suivantes présentées dans le tableau 1.1 s'appliquent au véhicule hybride série-parallèle intégré dans le simulateur HEVMBFS:

Dimensions	Le poids à vide	1325 kg
	La longueur	4450 mm
	La largeur	1725 mm
	la taille	1490 mm
Performance	La gamme totale	870 km
	La gamme électrique	18 km

Tableau 1.1. Configuration système globale requise.

Il est à souligner que différents composants sont utilisés dans le simulateur HEVMBFS, nous allons détailler quelques-uns:

1.3.1 Moteur à combustion




Figure 1.5: Bloc diagramme du moteur à combustion interne.

Le bloc diagramme de la figure 1.5 représente un moteur à combustion interne général. Deux choix sont possibles afin de sélectionner le type du moteur à combustion, soit allumage par étincelle ou diesel. Le paramétrage de la puissance-vitesse et du couple-vitesse sont fournis. Une entrée de signal physique d'accélérateur spécifie le couple moteur normalisé. Les paramètres dynamiques optionnels comprennent l'inertie du vilebrequin et le retard de réponse. Une sortie de signal physique du moteur à combustion produit le taux de consommation du carburant en fonction du choix du modèle. Un variateur de vitesse en option empêche le calage du moteur et active le régulateur de vitesse.

Puissance	57 kW @5000 tr/min
Vitesse minimale	1000 tr/min
Vitesse maximale	4500 tr/min
Couple	115 Nm @4200 tr/min

Tableau 1.2. Configuration système requise pour le moteur à combustion.

Les caractéristiques présentent dans le tableau 1.2 s'appliquent à la fonctionnalité de ce module.

1.3.2 Train épicycloïdal




Figure 1.6: Bloc train épicycloïdal.

Le bloc diagramme présent dans la figure 1.6 modélise un train d'engrenages comportant : le planétaire intérieur appelé 'soleil', des satellites, et le planétaire extérieur appelé 'couronne'. Les trains épicycloïdaux sont courants dans les systèmes de transmission, où ils offrent des rapports d'engrenages élevés dans des géométries compactes. Un

support relié à un arbre de transmission maintient les engrenages planétaires. Les ports C, R et S représentent les arbres reliés au porte-satellites, à la couronne et à la roue solaire.




Figure 1.7: Diagramme du train épicycloïdal.

Le bloc modélise le train épicycloïdal en tant que composant structurel basé sur les blocs 'Sun-Planet' et 'Ring-Planet' Simscape™ Driveline™. La figure 1.7 montre le diagramme de ce composant structurel.

1.3.3 Servomoteur




Figure 1.8: Bloc servomoteur.

Le bloc servomoteur, voir la figure 1.8, représente un modèle de moteur sans balais (Brushless) avec commande de couple en boucle fermée. Ce bloc simule le comportement couple-vitesse du moteur combiné et du moteur entraineur afin de prendre en charge la simulation au niveau du système car la vitesse est un indice de grande importance.

1.3.4 Bloc de commande

Le bloc de commande, voir figure 1.9 est composé de quatre contrôleurs et d'un sous bloc dédié pour le mode logique. Un contrôleur pour le moteur diesel, un contrôleur pour la génératrice, un contrôleur pour le moteur électrique et un contrôleur de la charge de la batterie et un mode logique qui assure la gestion énergétique pour un bon fonctionnement du système.




Figure 1.9: Bloc de commande.

La boucle de commande de la figure 1.10 illustre le contrôle de la vitesse du moteur à combustion, lorsque l'accélération est nulle, la vitesse est réglée automatiquement à 800 tr / min (vitesse de ralenti).




Figure 1.10: Régulateur de vitesse du moteur à combustion.

La boucle de régulation présentée dans la figure 1.11 indique le contrôle de la vitesse du moteur-générateur. La valeur maximale de la tension Wref est de 5 volts, ce qui équivaut à une demande de vitesse de 10000 tr / min.




Figure 1.11: Régulateur de vitesse de la génératrice.

La boucle de commande de la figure 1.12 montre le contrôle de la vitesse du moteur électrique, La valeur maximale de la tension Wref est de 5 volts, ce qui équivaut à une demande de vitesse de 6500 tr / min.




Figure 1.12: Régulateur de vitesse du moteur électrique.

Les régulateurs de vitesse du moteur à combustion, de la génératrice, et du moteur électrique, comportent au minimum un gain proportionnel et intégrateur.

$$C = K_p + \frac{K_i}{s} \quad (1)$$

Les paramètres des trois régulateurs de vitesse PI, voir tableau 1.3 sont réglés pour donner les meilleurs performances. Ces paramètres sont obtenus à partir du simulateur HEVMBFS.

	Gain proportionnel	Gain intégrateur
Régulateur de vitesse du moteur à combustion	$K_p = 0.02$	$K_i = 0.01$
Régulateur de vitesse de la génératrice	$K_p = 10$	$K_i = 3$
Régulateur de vitesse du moteur électrique	$K_p = 500$	$K_i = 300$

Tableau 1.3. Les paramètres optimaux pour les régulateurs de vitesse PI.

1.3.5 Gestion d'énergie

Le sous-système de gestion d'énergie joue un rôle important dans la consommation du carburant.

Le sous-système est composé de trois parties principales:

- Mode logique (Mode logic) qui gère les différents modes de fonctionnement du véhicule hybride.
- Un bloc de calcul d'énergie permet de fournir des entrées au moteur à combustion et au moteur électrique et ce en fonction de l'entrée de pédale d'accélération à une vitesse donnée.
- Le contrôleur du moteur à combustion assure au moteur thermique une commande dont la performance soit d'un niveau haut, sachant qu'il est la source principale d'énergie transformée en couple moteur. Quant aux contrôleurs du moteur électrique et de la génératrice ils assurent la commande de vitesse et du couple.

1.3.6 Mode logique

Pour gérer la consommation d'énergie de manière plus efficace, une connaissance approfondie de la gestion du flux d'énergie dans le système est nécessaire. Notons l'exemple dans la phase de décélération, l'énergie cinétique des roues peut être convertie, dans une certaine mesure, en énergie électrique pour charger les batteries. Cela implique que le système doit pouvoir fonctionner dans différents modes afin d'optimiser l'utilisation de l'énergie.




Figure 1.13: Mode logique modélisé avec Stateflow®.

Le diagramme Stateflow illustré par la figure 1.13, propose un seul mode qui regroupe plusieurs sous-modes. Les états "accélération" et "croisière" ont été regroupés pour former un mode nommé "Normal_mode", ce dernier mode est combiné avec l'état "faible vitesse / démarrage" pour former le super état appelé "Motion_Mode". Ce regroupement permet d'organiser le mode logique en une structure hiérarchique plus simple à visualiser et déboguer.

1.4 Conclusion

Dans ce chapitre, différents types d'architectures de véhicules hybrides ont été présentées. Nous avons introduit le simulateur HEVMBFS qui sera utilisé pour l'implémentation et la simulation des nouveaux régulateurs de vitesse. Aussi il sera question d'améliorer la gestion d'énergie dans les

prochains chapitres. Nous avons détaillé quelques composantes principales utilisées dans le simulateur HEVMBFS, ainsi que le régulateur de vitesse du moteur à combustion et du mode logique, ces deux derniers vont servir aux comparaisons futures.

CHAPITRE 2

Modélisation du moteur diesel

2.1. Introduction	23
2.2. Le modèle physique	23
2.3. Le modèle neuronal	26
2.4. Résultats de la simulation	31
2.5. Conclusion	38

2.1 Introduction

Ce travail porte essentiellement sur la modélisation du moteur diesel conçu pour les véhicules hybrides séries-parallèles (HEV), ce type d'hybridation est intéressant au niveau des objectifs mais complexe au niveau de l'optimisation des performances. Pour cela on impose une rigueur des plus sévères quant à l'approximation du modèle. Notre choix s'est porté sur un modèle neuronal pouvant réaliser un traitement réparti entre éléments et composants du modèle physique. Une étude comparative est effectuée sur plusieurs cycles avec et sans bruit blanc, mettant en examen la robustesse et la bonne conduite de ce modèle. L'utilisation du simulateur «HEVMBFS» et le modèle neuronal ont permis de dégager des résultats assez encourageants.

2.2 Le modèle physique

Pour cette étude nous allons considérer l'un des types d'injection existante à savoir le système d'injection haute pression à rampe commune. Ce dernier consiste à alimenter, à l'aide d'une pompe haute pression pilotée électroniquement par une rampe commune en anglais "Common Rail" (Han et al., 2014), qui assure la fonction d'accumulateur du carburant. Cette rampe est connectée à des injecteurs qui assurent une pulvérisation très fine directement dans la chambre de combustion grâce à une pression comprise entre 1350 et 2000 bars. Cette pulvérisation très fine permet d'améliorer la combustion (Lafifi et al., 2006). Voir le schéma représenté dans la figure 2.1.




Figure 2.1: Schéma simplifié du moteur diesel.

Le système est mis sous forme de représentation d'espace d'état dont les variables sont décrites dans le tableau 2.1:

Variable	Symbol	Désignation
u1	Xegr	Taux de recirculation du gaz d'échappement
u2	m _f	Débit d'injection
u3	x _{vgt}	Variation de la géométrie de la turbine
u4	M _{load}	Moment de charge
X1	n	Vitesse du vilebrequin
X2	P _{man}	Pression du collecteur d'admission
X3	m _{ff}	Débit du film d'injection
X4	P _c	Puissance du compresseur
X5	P _{ex}	Pression du collecteur d'échappement
X6	T _{man}	Température du collecteur d'admission
X7	T _{exo}	Température du collecteur d'échappement

Tableau 2.1. Grandeurs de la représentation de l'espace d'état.

Le modèle physique représentant le moteur diesel se compose des dynamiques suivantes:

-Dynamique de l'air d'admission représentée par les équations: **(3)**, **(5)**, **(7)**.

-Dynamique de la combustion donnée par les équations **(2)**, **(4)**.

-Dynamique de l'échappement donnée par les équations **(6)**, **(8)**.

$$\dot{x}_1 = \left(\frac{60}{2 \times \pi \times I_{tot}} \right) \times \left(\left(\frac{n_{fc} \times Q_{hv}}{2 \times \pi \times 60} \right) \times \frac{((1-X) \times u_2 + x_3)}{x_1} - M_{fiic}(x_1, x_2) - u_4 \right) \quad (2)$$

$$\dot{x}_2 = \frac{R \times x_6}{V_{man} \times 3600} (\dot{m}_a + \dot{m}_{egr} - \dot{m}_T) \quad (3)$$

$$\dot{x}_3 = \frac{1}{\tau_{ff}} (X \times u_2 - x_3) \quad (4)$$

$$\dot{x}_4 = \frac{1}{\tau} (\eta_m \times P_t - x_4) \quad (5)$$

$$\dot{x}_5 = \frac{R \times x_6}{V_d \times 3600} (u_2 - \dot{m}_{exo} - \dot{m}_{egr} + \dot{m}_T) \quad (6)$$

$$\dot{x}_6 = \frac{(\dot{m}_a \times (\gamma \times T_3 - x_6) + (\dot{m}_{egr} \times (\gamma \times T_{egr} - x_6)) - (\dot{m}_T \times (\gamma - 1) \times x_6)) \times R \times x_6}{V_{man} \times x_2} \quad (7)$$

$$\dot{x}_7 = \frac{(((\dot{m}_{egr} + \dot{m}_{exo}) \times (1 - \gamma)) - ((u_2 + \dot{m}_T) \times (1 - \gamma) \times x_7)) \times R \times x_7}{V_{man} \times x_5} \quad (8)$$

Le modèle est obtenu par les méthodes expérimentales basées sur les relations thermodynamiques et les relations mécaniques, il en résulte un modèle fortement non linéaire ce qui rend son utilisation pour la commande du système très difficile à mettre en œuvre. La modélisation des systèmes non linéaires par réseaux de neurones a fait l'objet de nombreux travaux de recherche depuis une dizaine d'années à cause de la capacité d'apprentissage, d'approximation et de généralisation que possèdent ces réseaux (Chen and Billings, 1992; Narendra, 1998). En effet, cette nouvelle approche fournit une solution efficace à travers laquelle de larges classes des systèmes non linéaires peuvent être modélisés sans une description mathématique précise.

Il existe plusieurs méthodes d'identification des systèmes non linéaire, dans cette partie nous avons porté une attention particulière à la modélisation du moteur diesel par le modèle neuronal.

2.3 Le modèle neuronal

Les modèles neuronaux les plus utilisés, les perceptrons multicouches en anglais "Multilayer Feed Forward Network, ou multilayer Perceptron=MLP", sont présentés dans le cadre de l'identification des systèmes non linéaire. (Norgaard et al., 2000; Pawlus et al., 2012). Le choix s'est porté sur la régression du modèle NARX "Nonlinear Autoregressive Neural Network With External Input" est composée des sorties et des entrées passées (Sjöberg et al., 1995), voir l'équation 9.

$$\hat{y}(k) = f(u(k-1), \dots, u(k-n), y(k-1), \dots, y(k-m)) \quad (9)$$

Afin de modéliser le moteur à combustion on doit d'abord l'isoler du simulateur HEVMBFS, puis injecter un signal avec différentes amplitudes et différentes variation. Dans le but d'obtenir des données riches en information pour l'estimation des paramètres du modèle du moteur diesel, voir figure 2.2.




Figure 2.2: Schéma de simulation de l'estimation des paramètres du modèle du moteur diesel.

Après simulation selon le schéma de la figure 2.2 nous obtenons les grandeurs d'entrée et de sortie représentées sur la figure 2.3.




Figure 2.3: Signal d'entrée-sortie du moteur à combustion.

Nous avons choisi un échantillon de données qui sera utilisé dans la phase d'apprentissage, et un autre pour le test du modèle neuronal. L'algorithme de Levenberg-Marquardt est utilisé pour la phase d'apprentissage des paramètres du réseau neuronal. Le modèle NARX est construit à partir d'une couche à quatre entrées, d'une couche cachée de quatre neurones et d'une couche de sortie d'un neurone, voir figure 2.4.




Figure 2.4: Le modèle neuronal NARX.

L'implémentation du modèle NARX sur Matlab/Simulink nous a permis l'obtention des résultats suivant :

- Le rendement d'apprentissage du modèle neuronal est représenté dans la figure 2.5.
- La régression est montrée dans la figure 2.6.




Figure 2.5: Rendement d'apprentissage du réseau neuronal.

A travers la figure 2.5 on peut voir trois courbes, la courbe bleue représente l'erreur de l'apprentissage, la courbe verte représente l'erreur de la validation, et la courbe rouge représente l'erreur du test. Au début de l'apprentissage, les erreurs sont généralement élevées; grâce à l'apprentissage, ces trois erreurs décroissent et deviennent négligeable.

Quant à la régression d'apprentissage du réseau neuronal celle-ci est présenté dans la figure 2.6.




Figure 2.6: Régression d'apprentissage du réseau neuronal.

Les trois graphes de la figure 2.6 représentent les données d'apprentissage, de validation et du test. La valeur R est une indication de la relation entre les sorties et les références. Les données d'apprentissage indiquent un bon ajustement. Les résultats de validation et du test montrent également des valeurs $R = 1$, cela indique qu'il existe une relation linéaire exacte entre les sorties et les références.

2.4 Résultats de la simulation

Après l'implémentation et la validation du modèle NARX, nous allons pouvoir tester ce dernier dans le simulateur HEVMBFS, cette architecture est montrée dans la figure 2.7.




Figure 2.7: Le modèle neuronal connecté au moteur à combustion dans un schéma de simulation du véhicule hybride.

L'entrée du moteur à combustion $u(t)$, est reliée à plusieurs unités de retard (Memory), afin de générer les entrées $u(t-1)$ et $u(t-2)$ du réseau neuronal. La sortie du moteur à combustion $y(t)$, est reliée à travers les

unités de retard à la troisième entrée du réseau neuronal $y(t-1)$ et à la quatrième entrée du réseau neuronal $y(t-2)$. La sortie du réseau neuronal est un modèle de régime du moteur à combustion, ce dernier sera comparé avec le régime du moteur à combustion réel. Un filtre passe-bas "Low-Pass Filter" appelé 'B', peut être manuellement sélectionné à travers l'interrupteur 'A' pour réduire l'effet de la perturbation sur le système. Ceci est utilisé pour tester la robustesse du modèle neuronal.




Figure 2.8: Régulateur de vitesse du moteur diesel.

Il est à souligner et après un certain nombre de simulation que des modifications ont été apportées au niveau du régulateur de vitesse PI par l'introduction d'une contrainte sur la commande "Le contour en vert (C)", afin de faire disparaître les pics d'accélération qui peuvent être très néfastes pour la bonne conduite du moteur, voir figure 2.8. Les figures 2.9 et 2.10 indiquent clairement l'allure des courbes de l'accélération avant et après modification de la valeur du limiteur.




Figure 2.9: Courbes d'accélération avant l'introduction de la contrainte.




Figure 2.10: Courbes d'accélération après l'introduction de la contrainte.

Nous avons obtenu les résultats de la simulation sous environnement Simulink comme représenté sur les figures 2.11, 2.12, 2.13, 2.14 et 2.15.

Les figures 2.11, 2.12 et 2.13 représentent la vitesse du moteur diesel réelle en rouge, et la vitesse du moteur diesel modélisé en bleu avec perturbation. Testé sur le cycle 1 qui est un cycle urbain (normes UDC), le véhicule atteint une vitesse maximale de 50 km / h comme le montre la figure 2.11. Tandis que pour le cycle 2 qui est un cycle extra-urbain (normes EUDC), il atteint une vitesse maximale de 120 km / h, voir figure 2.12. Enfin, pour le cas du cycle 3 (normes FTP75), il atteint une vitesse maximale de 90 km / h. Ce dernier cycle comprend de nombreuses variations de vitesse, ce qui est idéal pour tester la robustesse du modèle, comme le montre la figure 2.13.




Figure 2.11: Vitesse du moteur à combustion réelle (tr /min) et vitesse du moteur à combustion modélisée (tr /min) avec perturbation (cycle 1).




Figure 2.12: Vitesse du moteur à combustion réelle (tr /min) et vitesse du moteur à combustion modélisée (tr /min) avec perturbation (cycle 2).




Figure 2.13: Vitesse du moteur à combustion réelle (tr /min) et vitesse du moteur à combustion modélisée (tr /min) avec perturbation (cycle 3).

On remarque à peine la vitesse réelle en rouge sous la vitesse modélisée en bleu figure 2.11, 2.12 et 2.13, ce qui signifie que l'erreur de modélisation ε est presque nulle:

$$\varepsilon = Y_m - Y \quad (10)$$

Le vecteur d'erreur ε représente la différence entre la sortie du réseau neuronal Y_m et la sortie réelle Y . Les résultats sont présentés sur la figure 2.14.




Figure 2.14: La différence entre la vitesse du moteur diesel réelle et la vitesse du modèle neuronal avec perturbation.

La figure 2.15 montre le résultat de l'erreur entre la vitesse réelle et la vitesse modélisée. Nous remarquons que l'erreur est négligeable, bien qu'il reste quelques petites différences bruitées comme il est indiqué en gras.

Ces résultats sont satisfaisants malgré la présence de la perturbation, ainsi que pour le cycle 3 qui est riche en variations de vitesse. Les résultats seront plus satisfaisants dans le cas où l'interrupteur (A) est connecté à la broche supérieure, d'où l'introduction du filtre passe bas ce qui induit une réduction notable de la perturbation sur le système, voir figure 2.15.




Figure 2.15: Modèle neuronal connecté au moteur à combustion dans le diagramme de simulation du HEV avec atténuation des perturbations.

La figure 2.16 montre la différence entre la vitesse réelle du moteur à combustion et la vitesse modélisée, on remarque que l'erreur est négligeable et la perturbation est totalement réduite.




Figure 2.16: La différence entre la vitesse du moteur à combustion réelle et la vitesse du modèle neuronal avec réduction de perturbation.

2.5 Conclusion

Grâce au développement de méthodologie rigoureuse pour la conception de modèle, les réseaux de neurones sont devenus des modèles numériques puissants dont les domaines d'application sont multiples. Ils permettent de réaliser de manière simple et efficace des modèles précis non

linéaires, statiques ou dynamiques. Ce travail met en évidence l'effet de la perturbation sur le réseau neuronal pour la modélisation du moteur diesel. Nous remarquons que l'introduction de la perturbation n'influe aucunement sur le modèle neuronal, ainsi de bonnes performances sous différents cycles sont obtenues. Cela nous permet de confirmer que ce modèle est suffisamment robuste pour être utilisé dans une stratégie de contrôle intelligente. De ce fait, ce résultat pourrait conduire à optimiser la consommation du carburant du moteur à combustion et à réduire les émissions de NOx, ce qui est un plus pour la sauvegarde de l'environnement.

CHAPITRE 3

La commande prédictive à base de modèle linéaire

3.1. Introduction	41
3.2. La méthode SUBSPACE	41
3.3. La commande prédictive	43
3.4. Régulateur de vitesse	46
3.5. Résultats de la simulation	48
3.6. Conclusion	50

3.1 Introduction

Dans ce chapitre, notre choix s'est porté sur un modèle linéaire obtenu par la méthode d'identification de système SUBSPACE. Ce dernier exige que l'approximation du modèle soit faite avec grand soin. La commande prédictive est utilisée comme un régulateur de vitesse du moteur thermique. La première étape est d'approximer un modèle linéaire à partir des entrées et sorties du système à l'aide de la méthode SUBSPACE. Ensuite, le modèle du système est utilisé par la commande prédictive afin de contrôler le régime du moteur à combustion. Enfin, on explique comment l'implémentation est faite du bloc de commande prédictive dans l'environnement Simulink.

3.2 La méthode SUBSPACE

Au début des années 90, un nouveau type d'algorithmes d'identification de systèmes, appelé méthode SUBSPACE, a été introduite dans le contrôle automatique pour l'identification des systèmes linéaires multi-variables invariants dans le temps "Linear Time-Invariant". Essentiellement, cette méthode constitue une bonne alternative aux méthodes classiques d'optimisation non linéaire basées sur l'erreur de prédiction (Ljung, 1999). La méthode de SUBSPACE ne nécessite pas de paramétrage explicite du système; cela la rend numériquement intéressante et particulièrement adaptée aux systèmes multi-variables. Cette dernière peut également être utilisée pour générer le point de départ initial pour les méthodes d'erreur de prédiction itérative. Cette combinaison de méthodes de SUBSPACE et d'erreur de prédiction est un outil puissant pour déterminer les paramètres

d'un système linéaire invariants dans le temps à partir de mesures d'entrée et de sortie (Westwick and Michel, 1996; Chou and Verhaegen, 1999).

La méthode d'identification SUBSPACE concerne les systèmes et des modèles de la forme suivante:

$$x_{k+1} = Ax_k + Bu_k + w_k \quad (11)$$

$$y_k = Cx_k + Du_k + v_k \quad (12)$$

Avec

$$E = \begin{bmatrix} \begin{pmatrix} w_p \\ v_p \end{pmatrix} & (w_q^T \quad v_q^T) \end{bmatrix} = \begin{pmatrix} Q & S \\ S^T & R \end{pmatrix} \delta_{pq} \geq 0 \quad (13)$$

Les vecteurs $u_k \in R^{m \times 1}$ et $y_k \in R^{l \times 1}$ sont les mesures à l'instant k de m entrées et l sorties du processus. Le vecteur x_k est le vecteur d'état du processus à un instant discret k , $v_k \in R^{l \times 1}$ et $w_k \in R^{n \times 1}$ sont des signaux vectoriels non observés, v_k est appelé bruit de mesure et w_k est appelé bruit de processus, considérés comme étant des séquences vectorielles de bruit blanc stationnaire et non corrélées avec les entrées u_k . $A \in R^{n \times n}$ est la matrice du système, $B \in R^{n \times m}$ est la matrice d'entrée, $C \in R^{l \times n}$ est la matrice de sortie, tandis que $D \in R^{l \times m}$ est la matrice d'application directe des entrées. Les matrices $Q \in R^{n \times n}$, $S \in R^{n \times 1}$ et $R \in R^{l \times 1}$ sont les matrices de covariance des séquences de bruit w_k et v_k .

3.3 La commande prédictive

La commande prédictive "Model Predictive Control (MPC)" a été reconnue comme une approche efficace pour améliorer l'efficacité opérationnelle et la rentabilité (Harida et al., 2017; Kim et al., 2009; Yan et al., 2012). Cette méthode avancée a la capacité d'anticiper les futurs événements et peut prendre des mesures de contrôle en conséquence. Les contrôleurs classiques comme LQR et PID n'ont pas cette capacité prédictive. La commande prédictive est un algorithme de contrôle multi-variable qui repose sur des modèles dynamiques du processus (Vichik and Borrelli, 2014), le plus souvent des modèles empiriques linéaires obtenus par identification de système (Hsieh and Liu, 2016; Wang et al., 2014). Une fonction de coût J est minimisée afin d'obtenir la commande optimale (Findeisen et al., 2006). L'optimisation de la fonction de coût est donnée par:

$$J(z_k) = \sum_{i=0}^{p-1} \{ [e_Y^T(k+i) Q e_Y(k+i)] + [e_u^T(k+i) R_u e_u(k+i)] + [\Delta u^T(k+i) R_{\Delta u} \Delta u(k+i)] \} + \rho k^2 \quad (14)$$

Ici, Q ($ny - by - ny$), R_u , et $R_{\Delta u}$ ($nu - by - nu$) sont des matrices de pondération semi-définie positive, avec les erreurs :

$$e_y(i+k) = S_y^{-1} [r(k+i+1|k) - y(k+i+1|k)] \quad (15)$$

$$e_u(i+k) = S_u^{-1} [u_{\text{target}}(k+i|k) - y(k+i|k)] \quad (16)$$

$$\Delta u(k+i) = S_u^{-1} [u(k+i|k) - u(k+i-1|k)] \quad (17)$$

Aussi,

- S_y , La matrice diagonale de la sortie du système avec facteur d'échelle variable.
- S_u , La matrice diagonale de la grandeur d'entrée avec facteur d'échelle variable.
- $r(k+1|k)$, n_y valeur de référence de sortie système à l'ième phase d'horizon de prédiction.
- $y(k+1|k)$, n_y sortie système à l'ième phase d'horizon de prédiction.
- z_k , décision de la programmation quadratique, donnée par:

$$z_k^T = [u(k|k)^T \ u(k+1|k)^T \ ... \ u(k+p-1|k)^T] \quad (18)$$

- $u_{target}(k+i|k)$, n_u Valeurs de référence correspondant à $u(k+i|k)$.

Les contraintes de la commande prédictive les plus courantes sont les limites, comme suit :

$$U_{min} < U < U_{max} \quad (19)$$

$$Y_{min} < Y < Y_{max} \quad (20)$$

$$\Delta U_{min} < \Delta U < \Delta U_{max} \quad (21)$$

L'efficacité de cette méthode est principalement due au fait qu'une trajectoire de référence connue ou pré calculée (au moins sur un certain

horizon), il est possible d'exploiter pleinement les informations de trajectoires prédéfinies situées dans le futur.




Figure 3.1: Schéma de principe de la stratégie de la commande prédictive.

Le but de la stratégie prédictive est de faire l'ajustement entre la sortie du processus et la trajectoire de référence prédéterminée sur un horizon fini dans le futur, tel qu'illustré sur le diagramme de la figure 3.1. Ainsi, cette méthode semble très appropriée pour traiter efficacement les problèmes de référence et surtout celle de suivi de trajectoire.

3.4 Régulateur de vitesse

Le contrôle de la vitesse du moteur à combustion basé sur la commande prédictive à base de modèle linéaire est illustré dans la figure 3.2. Un port est ajouté pour activer ou désactiver (Enable/Disable) le régulateur de vitesse à tout moment. Ce degré de liberté est introduit afin d'éviter le fonctionnement du régulateur lors de la non permission par le mode logique.




Figure 3.2: Régulateur de vitesse du moteur à combustion à base de MPC.

Les paramètres illustrés sur le tableau 3.1 sont ajusté afin de permettre d'obtenir les meilleures performances possibles.

Les paramètres	Les valeurs
L'horizon minimal de prédiction (N_1)	1
L'horizon maximal de prédiction (N_2)	10
L'horizon de prédiction sur la commande (N_u)	1
Période d'échantillonnage	0.005 s

Tableau 3.1. Les paramètres optimaux pour le régulateur de vitesse MPC.

L'horizon minimal de prédiction N_1 est égale à 2, ce dernier paramètre est calculer à partir de l'équation 22, et l'horizon maximal de prédiction N_2 est obtenu à partir de l'équation 23.

$$N_1 = \frac{\text{retard pur du système}}{\text{période d'échantillonnage}} \quad (22)$$

$$N_2 \leq \frac{\text{temps de réponse du système}}{\text{période d'échantillonnage}} \quad (23)$$

D'après plusieurs simulations, le retard du système ne dépasse pas une seconde; quand le retard est mal connu on prend $Nu = 1$. La période d'échantillonnage est calculée selon les conditions de Shannon, voir l'équation 24.

$$\text{période d'échantillonnage} \leq \frac{\text{constante du temps}}{10} \quad (24)$$

Les contraintes sur la commande prédictive sont présentées dans le tableau 3.2.

Les contraintes	Les valeurs
U_{Min}	0
U_{Max}	1
Y_{Min}	800 (tr / min)
Y_{Max}	4500 (tr / min)

Tableau 3.2. Les contraintes appliquées sur la commande MPC.

3.5 Résultats de la simulation

Après l'implémentation de la commande prédictive à base de modèle linéaire et après un certain nombre d'essais suffisant en simulation, nous avons obtenu les résultats dans l'environnement Simulink comme indiqué sur la figure 3.3 et 3.4.

Le premier test de la commande prédictive à base de modèle linéaire a été effectué sur le cycle 1 qui est un cycle de conduite urbaine (normes UDC) répété quatre fois dont la vitesse maximal peut atteindre 50 km/h, voir la figure 3.3.




Figure 3.3: Le contrôleur MPC testé sur le cycle urbain (UDC).

Cette figure 3.3 illustre 4 courbes; la vitesse réelle (tr / min) avec la référence du régime moteur à combustion dans le même graphe, le couple du moteur à combustion (Nm), la puissance du moteur thermique (W) et l'accélération.

Le second test de la commande prédictive à base de modèle linéaire a été réalisé sur le cycle 2 qui est un cycle de conduite extra-urbain (normes EUDC), ce dernier pourra atteindre une vitesse maximal de de 120 km/h est illustré sur la figure 3.4.




Figure 3.4: Le contrôleur MPC testé sur le cycle extra-urbain (EUDC).

La figure 3.4 illustre 4 courbes; la vitesse réelle du moteur (tr / min) avec la référence du régime moteur à combustion dans le même graphe, le couple du moteur à combustion (Nm), la puissance du moteur thermique (W) et l'accélération.

Nous remarquons que la commande prédictive à base de modèle linéaire produit une commande adaptée avec un effet minimale sur la demande de l'accélération du moteur à combustion. On s'aperçoit aussi que le contrôleur MPC génère la commande juste à l'instant nécessaire pour suivre les différents cycles de référence et s'annule à la vitesse de ralenti (800 tr / min), voir figure 3.3.

3.6 Conclusion

A l'aide de développement de méthode efficace pour la conception de modèles et d'algorithmes de commande et d'optimisation, nous avons utilisé la méthode SUBSPACE pour obtenir un modèle linéaire du moteur à combustion. Ce dernier ayant fait l'objet d'application de la commande prédictive. Nous avons remarqué que les résultats de la simulation dans divers scénarios de différents cycles sont satisfaisants. Cela nous permet d'affirmer que le contrôleur MPC remplit bien les objectifs fixés au départ, à savoir une conduite plus confortable et une longévité accrue des équipements du véhicule hybride. Enfin, ce travail ouvre d'avantage la voie d'améliorer le modèle par d'autres types d'algorithmes d'identification du système, afin d'obtenir une commande intelligente plus satisfaisante et plus performante.

CHAPITRE 4

La commande prédictive à base de modèle neuronal

4.1. Introduction	52
4.2. Modèle neuronal	52
4.3. La commande prédictive	58
4.4. Régulateur de vitesse	59
4.5. Résultats de la simulation	61
4.6. Conclusion	64

4.1 Introduction

L'implémentation de la commande prédictive à base de modèle neuronal "Neural Network Predictive Control (NNPC)" à partir de la boîte à outils "Neural Network Toolbox software" utilise un modèle du réseau neuronal d'un système non linéaire pour prédire les futures performances du système. Le contrôleur calcule la commande d'entrée optimisant ainsi les performances du système sur un futur horizon temporel spécifié. La première étape de la commande prédictive est de déterminer le modèle neuronal du système par identification du système. Ensuite, le modèle du système est utilisé par le contrôleur pour prédire les performances futures. La partie suivante décrit le processus d'identification du système, celle-ci est suivie d'une description du processus d'optimisation. Enfin, on explique comment l'implémentation est faite du bloc de la commande prédictive dans l'environnement Simulink.

4.2 Modèle neuronal

La première étape avant l'application de la commande prédictive est l'apprentissage du réseau neuronal pour représenter une dynamique progressive du système. L'erreur de prédiction entre la sortie du système et la sortie du réseau neuronal est utilisée comme un signal d'apprentissage du réseau neuronal. Le processus est représenté par la figure 4.1.




Figure 4.1: Processus d'apprentissage du réseau neuronal.

Le modèle neuronal du système utilise les entrées et les sorties précédentes du système pour prédire les valeurs futures de la sortie du processus. La structure du modèle neuronal du système est donnée dans la figure 4.2.




Figure 4.2: La structure du réseau neuronal du système.

L'apprentissage du réseau neuronal pourra être effectué hors ligne, en utilisant les données collectées à partir de l'entrée sortie du système. Plusieurs algorithmes d'apprentissage pourraient être utilisés.

Le modèle neuronal présenté dans le deuxième chapitre ne peut être utilisé directement dans la commande prédictive, car c'est une représentation continue. Il faudra alors générer un autre modèle en temps discret avec des unités de retard discrètes et une boucle fermée afin d'être compatible avec la commande prédictive. La figure 4.3 montre la structure du modèle NARX qui se compose d'une entrée, une couche cachée de quatre neurones, une couche de sortie d'un neurone et une sortie.




Figure 4.3: Modèle neuronal NARX.

L'étape d'apprentissage du réseau neuronal est sa mise en œuvre menée afin d'obtenir et validé les performances désirées, elle est représentée sur la figure 4.4.




Figure 4.4: Performance d'apprentissage du réseau neuronal.

Nous remarquons que les trois erreurs d'apprentissage, du test et de la validation sont d'un niveau très élevées avant le commencement d'apprentissage, grâce à l'algorithme d'apprentissage Levenberg-Marquardt, les trois erreurs prennent des valeurs faibles et deviennent presque nulle asymptotiquement.

Les graphes de régression sont présentés sur la figure 4.5.




Figure 4.5: Régression d'apprentissage du réseau neuronal.

Les trois graphes de la figure 4.5 représentent les données d'apprentissage, la validation et le test. La ligne en pointillée dans chaque graphe représente le résultat désiré, cela signifie que les sorties vont se superposer aux références. La ligne continue représente le meilleur ajustement de la régression linéaire entre les sorties et les références. La valeur R est une indication de la relation entre les sorties et les références; si $R = 1$ cela indique qu'il existe une relation linéaire exacte entre les sorties et

les références et si R est proche de zéro il n'y a pas de relation linéaire entre ces grandeurs. Dans notre cas, les données d'apprentissage indiquent un bon ajustement, les résultats de validation et le test montrent également des valeurs de R supérieur à 0,9.

Les graphes des données de validation sont illustrés sur la figure 4.6.




Figure 4.6: Données de validation de la commande prédictive à base de modèle neuronal.

Les résultats de performance du modèle neuronal par rapport au système physique sont illustrés dans la figure 4.6; celle-ci contient quatre courbes, le signal de commande, le signal de sortie du système, le signal de

sortie du modèle neuronal, et l'erreur. Nous remarquons que l'erreur relative aux données de validation est assez faible.

Enfin, après la phase d'apprentissage et la validation du modèle neuronal, il sera alors possible d'utiliser cette structure dans la commande prédictive.

4.3 La commande prédictive

La méthode de la commande prédictive est basée sur la technique de l'horizon fuyant "The Receding Horizon Technique" (Soloway and Haley, 1996). Le modèle neuronal prédit la réponse du processus sur un horizon temporel donné. Les prédictions sont utilisées par un programme d'optimisation numérique pour déterminer le signal de commande qui minimise le critère de performance sur un horizon spécifié, voir l'équation 25.

$$J = \sum_{j=N_1}^{N_2} (y_r(t+j) - y_m(t+j))^2 + \rho \sum_{j=1}^{N_u} (u'(t+j-1) - u'(t+j-2))^2 n \quad (25)$$

N_1 , N_2 et N_u définissent les horizons sur lesquels les erreurs de poursuite et la commande sont évaluées. La variable u' est une tentative de signal de commande. y_r est la réponse désirée et y_m est la réponse du modèle neuronal. La valeur ρ détermine la contribution de la somme des carrés de la commande dans l'indice de performance.

Le diagramme présenté dans la figure 4.7 illustre le diagramme du processus de la commande prédictive. Le contrôleur constitué du modèle neuronal déjà établie et du bloc d'optimisation. Le bloc d'optimisation détermine les valeurs de u' qui minimise le critère J , ainsi la commande optimale u est injectée à l'entrée du système.




Figure 4.7: Schéma fonctionnel de la commande prédictive à base de modèle neuronal.

4.4 Régulateur de vitesse

Le régulateur de vitesse du moteur à combustion représenté dans la figure 4.8 illustre le contrôle de la vitesse du moteur à combustion basé sur la commande prédictive à base de modèle neuronal. Un port est ajouté pour activer ou désactiver (Enable/Disable) le régulateur de vitesse à tout moment.




Figure 4.8: Régulateur de vitesse du moteur à combustion à base de NNPC.

Les paramètres	Les valeurs
L'horizon minimal de prédiction (N_1)	1
L'horizon maximal de prédiction (N_2)	10
L'horizon de prédiction sur la commande (N_u)	1
Période d'échantillonnage	0.002 s

Tableau 4.1. Les paramètres optimaux pour le régulateur de vitesse NNPC.

Les paramètres de régulateur de vitesse du moteur à combustion basé sur la commande prédictive à base de modèle neuronal sont illustrés sur le tableau 4.1. Un ajustement de ces paramètres permet d'obtenir les meilleures performances possibles.

L'horizon minimal de prédiction N_1 est fixé à 1 dans notre application, mais il est possible aussi de le calculer à partir de l'équation 22 dans le chapitre précédent, de même pour l'horizon maximal de prédiction N_2 qui a été calculé à partir de l'équation 23, ainsi la période d'échantillonnage qui a

été calculée selon les conditions de Shannon, voir l'équation 24 dans le chapitre précédent.

Les contraintes sur la commande prédictive sont présentées dans le tableau 4.2.

Les contraintes	Les valeurs
U_{Min}	0
U_{Max}	1
Y_{Min}	800 (tr / min)
Y_{Max}	4500 (tr / min)

Tableau 4.2. Les contraintes appliquées sur la commande NNPC.

4.5 Résultats de la simulation

Après l'implémentation et la simulation de la commande prédictive à base de modèle neuronal, nous avons obtenu les résultats dans l'environnement Simulink comme représenté sur la figure 4.9 et 4.10.

La figure 4.9 représente la vitesse réelle du moteur (tr / min) et la vitesse de référence du régime moteur, le couple moteur (Nm), la puissance du moteur (W) et l'accélération; en utilisant la commande prédictive à base de modèle neuronal. La dite implémentation a été testée sur le cycle 1 qui est un cycle de conduite urbaine (normes UDC) répété quatre fois.




Figure 4.9: Le contrôleur NNPC testé sur cycle urbain (UDC).

La figure 4.10 représente la vitesse réelle du moteur (tr / min) et la vitesse de référence du régime moteur, le couple moteur (Nm), la puissance du moteur (W) et l'accélération; en utilisant la commande prédictive à base de modèle neuronal. Cette dernière simulation est testée sur le cycle 2 qui est un cycle de conduite extra-urbain (normes EUDC).




Figure 4.10: Le contrôleur NNPC testé sur le cycle extra-urbain (EUDC).

Nous remarquons que la commande prédictive à base de modèle neuronal génère une commande appropriée avec un effet réduit sur la demande du moteur. On observe que la commande du contrôleur NNPC est générée juste au moment requis pour suivre les différents cycles de référence et s'annule au repos, voir les figures 4.9 et 4.10.

4.6 Conclusion

La commande prédictive est devenue un outil puissant dont les domaines d'application sont multiples, elle constitue spécifiquement une solution efficace pour la commande du moteur thermique. La commande prédictive à base de modèle neuronal a permis d'améliorer les résultats obtenus et présentés dans le chapitre précédent en utilisant la commande prédictive à base de modèle linéaire. Dans le chapitre suivant il est question de mener une étude de comparaison avec la méthode classique afin d'obtenir la meilleure stratégie de commande globale.

CHAPITRE 5

Gestion d'énergie améliorée et l'étude comparative

5.1 Introduction	66
5.2 Gestion d'énergie améliorée	66
5.3 Résultats de l'étude de comparaison	69
5.3.1 Comparaison avec le mode logique désactivé.....	69
5.3.2 Comparaison avec le mode logique activé.....	72
5.4 Conclusion	80

5.1 Introduction

Dans ce chapitre, nous allons entamer une procédure de modification touchant directement la gestion d'énergie afin de réduire le niveau de consommation du carburant. La seconde étape comporte une étude de comparaison d'une part entre les différentes méthodes et les stratégies de commande développées telle que MPC, NNPC, plus la gestion d'énergie améliorée ; d'autre part avec la méthode de stratégies de commande globale existante munit d'un régulateur PI. Sachant que cette dernière a fait l'objet d'une discussion dans le premier chapitre.

5.2 Gestion d'énergie améliorée

Dans la gestion d'énergie améliorée présentée dans la figure 5.1 nous proposons deux modes de mouvement (ou 'Motion_mode' en Anglais) , le mode principale nommé 'Main_Mode' peut atteindre une vitesse inférieure à une vitesse donnée V_1 ; le mode à grande vitesse appelé 'High_Speed_Mode' peut atteindre une vitesse supérieure à V_1 et sera limité à 120 km / h. Les modes d'accélération 'Accelerate_LS' et mode de croisière 'Cruise_LS' ont été combinés en un seul mode nommé 'Low_Speed_Mode' ou mode à une vitesse lente, ce dernier peut être combiné avec le mode de démarrage 'Start_mode' pour former le mode principale 'Main_Mode'. Le mode croisière à une vitesse lente 'Cruise_LS' est le mode idéal pour recharger la batterie à travers la génératrice, pour cela il regroupe deux modes; le mode de la recharge de la batterie 'Charge' et le mode d'arrêt de la recharge de la batterie 'No_Charge'. Il est à souligner que le niveau bas ainsi que le niveau haut de charge de la batterie est limité respectivement à 30% et 99,9%. Grâce à cette structure, on obtient une hiérarchie du Mode logique amélioré,

plus facile à visualiser et à déboguer. Le groupement du mode à une vitesse lente 'Low_Speed_Mode', est également appliqué aux modes d'accélération à grande vitesse 'High_Speed_Mode'.




Figure 5.1: La gestion d'énergie améliorée.

Le Mode logique amélioré est programmé sous Matlab / Stateflow® représenté sur la figure 5.1. Notons que les vitesses sont régies par les deux équations suivantes:

$$50 \leq V_1 \leq 120 \quad (26)$$

$$V_2 = V_1 - 1 \quad (27)$$

Pour mieux comprendre le fonctionnement du mode logique amélioré, nous allons détailler les règles d'activation / désactivation des régulateurs de vitesses de chaque moteurs, voir le tableau 5.1.

	Génératrice (Gen_Enable)	Moteur électrique (Mot_Enable)	Moteur à combustion (ICE_Enable)
Mode de démarrage 'Start_mode'	Activé	Activé	Désactivé
Mode d'accélération 'Accelerate_LS'	Désactivé	Activé	Désactivé
Mode d'accélération 'Accelerate_HS'	Désactivé	Activé	Activé
le mode de la recharge de la batterie 'Charge'	Activé	Activé	Désactivé
le mode d'arrêt de la recharge de la batterie 'No_Charge'	Désactivé	Activé	Désactivé
le mode de la recharge de la batterie 'Start_Charging'	Activé	Activé	Activé
le mode d'arrêt de la recharge de la batterie 'Stop_Charging'	Désactivé	Activé	Activé

Tableau 5.1. Les règles d'activation ou désactivation des régulateurs de vitesses.

D'après le tableau 5.1 on remarque que le moteur à combustion et en marche seulement dans le mode à grande vitesse, cela signifie que la voiture hybride et complètement électrique dans la sélection automatique du mode principale et hybride dans le mode à grande vitesse.

5.3 Résultats de l'étude de comparaison

5.3.1 Comparaison avec le mode logique désactivé

Dans cette partie nous allons présenter une étude en comparaison entre les trois contrôleurs PI, MPC, NNPC. Les résultats de la simulation du contrôleur PI sous l'environnement Simulink est représentée sur la figure 5.2, et les résultats obtenus en simulant la commande prédictive à base de modèle linéaire est donnée sur la figure 5.3. Enfin, la figure 5.4 montre les résultats obtenus en simulant la commande prédictive à base de modèle neuronal.




Figure 5.2: Résultats de simulation obtenus à l'aide du régulateur de vitesse PI du moteur à combustion testé sur le cycle NEDC.

Il est à remarquer que la simulation est obtenue en utilisant le simulateur HEVMBFS dans le cas où le Mode Logique est désactivé. L'ensemble est testé sur le nouveau cycle européen de conduite (NEDC); ce dernier est composé de deux parties, un cycle de conduite urbain (CDU) répété 4 fois, tracé de 0 s à 780 s et un cycle de conduite extra-urbain (EUDC) tracé de 780 s à 1180 s.

La figure 5.2 représente quatre courbes relative à une simulation en présence du régulateur PI; la vitesse réelle du moteur à combustion (tr / min), le couple du moteur à combustion (Nm), la puissance du moteur à combustion (W), et le signal d'accélération du moteur à combustion.




Figure 5.3: Résultats de simulation obtenus à l'aide du régulateur de vitesse MPC du moteur à combustion testé sur le cycle NEDC.

La figure 5.3 représente la vitesse réelle du moteur à combustion (tr / min), le couple du moteur à combustion (Nm), la puissance du moteur à combustion (W), et le signal d'accélération du moteur à combustion en utilisant la commande prédictive à base de modèle linéaire, testé sur le cycle NEDC.




Figure 5.4: Résultats de simulation obtenus à l'aide du régulateur de vitesse NNPC du moteur à combustion testé sur le cycle NEDC.

La figure 5.4 représente la vitesse réelle du moteur à combustion (tr / min), le couple moteur à combustion (Nm), la puissance du moteur à combustion (W), et le signal d'accélération du moteur à combustion en

utilisant la commande prédictive à base de modèle neuronal, testé sur le cycle NEDC.

Nous remarquons en premier lieu que le moteur subit des accélérations intempestives il est alors soumis à un effort inutile suite à la commande produite par le régulateur PI. Ce régime peut affecter fortement les performances du moteur à long terme, voir figure 5.2. En revanche, la commande prédictive à base de modèle neuronal génère une commande appropriée avec un effet réduit sur une sollicitation intempestive du moteur. L'amplitude du signal d'accélération du contrôleur prédictive NNPC est bien inférieure à celle du contrôleur PI et MPC. De plus, on observe que la commande des contrôleurs MPC et NNPC génère l'accélération juste au moment requis pour suivre les différents cycles de référence et seront nulle au repos. Il est donc clair que la commande prédictive de modèle neuronal est plus avantageuse, voir figure 5.4. Le contrôleur proposé pourrait être bien recommandé pour une utilisation dans une telle stratégie de contrôle.

5.3.2 Comparaison avec le mode logique activé

Après avoir choisi le contrôleur le plus performant dans la partie précédente on passera à la seconde partie du test à savoir activer le mode logique. Les résultats de ce premier test utilisant le régulateur de vitesse PI avec le mode logique activé sont présentés dans les figures 5.5, 5.6, et 5.7.




Figure 5.5: Les signaux d'entrées du mode logique.

Le mode logique a quatre signaux d'entrées (signal de vitesse du véhicule, le signal de freinage, signal de la charge de la batterie et le signal de vitesse du moteur à combustion) représentés dans la figure 5.5. Au début de la simulation, la batterie est recharger à 99,9%, la charge décroît durant le régime électrique à un niveau de 58%. Grace à la mise en fonction du moteur à combustion la batterie ce charge jusqu'à 79% à travers la génératrice. Notons que la récupération d'énergie lors de la phase freinage n'a pas été considérée.




Figure 5.6: Les signaux de sorties du mode logique.

Les signaux de sortie du mode logique présenté dans la figure 5.6, sont des signaux binaires connectés aux contrôleurs du moteur à combustion, de la génératrice et du moteur électrique ; '0' pour désactiver les régulateurs de vitesse et '1' pour activer les régulateurs de vitesse. On remarque que le régulateur de vitesse du moteur électrique est activé pendant toute la durée du cycle NEDC et que le régulateur du moteur à combustion s'active seulement à partir de 840 s c'est à dire lorsque la vitesse du véhicule atteint 50 km/h.




Figure 5.7: Résultats de simulation obtenus à l'aide du régulateur de vitesse PI du moteur à combustion et le mode logique testé sur le cycle NEDC.

La figure 5.7 montre la vitesse réelle du moteur à combustion (tr / min), le couple moteur à combustion (Nm), la puissance du moteur à combustion (W), et le signal d'accélération du moteur à combustion en utilisant le contrôleur PI avec le Mode logique, testé sur le cycle NEDC.

Durant la phase électrique le moteur à combustion est mis au ralenti avec une vitesse de 800 tr / min et une accélération nul comme illustré dans la figure 5.7. En utilisant la gestion d'énergie associée au contrôleur PI du moteur thermique, nous remarquons que le moteur est activé uniquement

dans le cycle de conduite extra-urbain (EUDC). Nous notons également que le pic observé dans la courbe d'accélération apparaît également dans le couple et la puissance du moteur à combustion, voir figure 5.7. La consommation du carburant est également de 2.146 L / 100. Ces derniers résultats seront comparés avec la gestion d'énergie améliorée et le meilleur contrôleur obtenu NNPC, afin d'obtenir plus d'économie sur le carburant et des meilleures performances.

Enfin, la dernière étape du test est d'utiliser le régulateur de vitesse NNPC avec la gestion d'énergie améliorée. Les résultats de ce test sont représentés dans les figures 5.8, 5.9, et 5.10.




Figure 5.8: Les signaux d'entrées du mode logique amélioré.

Le mode logique amélioré a quatre signaux d'entrées (signal de vitesse du véhicule, le signal de freinage, signal de la charge de la batterie et le signal de vitesse du moteur à combustion) présentées dans la figure 5.8. Au début de la simulation, la batterie est rechargée à 99,9%, le niveau de la charge de la batterie atteint 47% en fin de cycle. Notons que cette valeur sera plus élevée si on considère la récupération d'énergie à partir du freinage. Ce test a été réalisé à l'aide du régulateur de vitesse NNPC associé à la gestion d'énergie amélioré, les choix de la vitesse V1 et V2 du Mode logique amélioré pourrai augmentée ou diminuée le niveau de charge de la batterie, mais aura un effet inverse sur la consommation du carburant et la quantité d'émission Nox nuisible à l'environnement. Les paramètres utilisés dans ce test sont V1= 80 km/h , V2= 79 km/h.




Figure 5.9: Les signaux de sorties du mode logique amélioré.

Les signaux de sortie du mode logique amélioré présentés dans la figure 5.9 sont des signaux binaires connectés aux contrôleurs du moteur à combustion, de la génératrice et du moteur électrique. L'état '0' pour désactiver les régulateurs de vitesse et '1' pour activer les régulateurs de vitesse. On remarque que le régulateur de vitesse du moteur électrique est activé pendant toute la durée du cycle NEDC, et que le régulateur du moteur à combustion est activé seulement à partir de 1080 s, lorsque la vitesse du véhicule atteint 80 km/h.




Figure 5.10: Résultats de simulation obtenus à l'aide du régulateur de vitesse NNPC du moteur à combustion et le mode logique améliorée testé sur le cycle NEDC.

La figure 5.10 présente la vitesse réelle du moteur à combustion (tr / min), le couple du moteur à combustion (Nm), la puissance du moteur à combustion (W), et le signal d'accélération du moteur à combustion en utilisant le contrôleur NNPC avec le Mode logique améliorée, testé sur le cycle NEDC.

En utilisant la gestion d'énergie améliorée associée au contrôleur NNPC du moteur à combustion, nous remarquons que le régulateur de vitesse du moteur thermique est activé lorsque la vitesse est supérieure à 80 km / h, nous apercevons aussi que les pics ont disparus dans le couple et la puissance du moteur à combustion. La consommation de carburant est de 1,762 L / 100.

	Gestion d'énergie			Gestion d'énergie améliorée V1 = 60, V2 = 59			Gestion d'énergie améliorée V1 = 80, V2 = 79		
Contrôleur	PI	MPC	NNPC	PI	MPC	NNPC	PI	MPC	NNPC
Litre /100	2.146	2.13	2.115	2.024	2.002	1.989	1.782	1.771	1.762
Km/Litre	46.6	46.95	47.29	49.4	49.96	50.28	56.11	56.48	56.76
MPG	109.6	110.4	111.2	116.2	117.5	118.3	132	132.8	133.5
Carburant total utilisé (L)	0.2346	0.2328	0.2312	0.2213	0.2188	0.2174	0.1948	0.1936	0.1926

Tableau 5.2. Économie de carburant obtenus durant le test dans cycle NEDC.

Le tableau 5.2 montre les différentes quantités de consommation de carburant dans le cycle NEDC. On remarque lorsqu'on utilise un contrôleur NNPC avec la gestion d'énergie et la gestion d'énergie améliorée, la consommation de carburant reste inférieure à celle obtenue par le contrôleur PI et le contrôleur MPC. De plus, l'introduction de la gestion d'énergie

améliorée optimise la quantité de consommation du carburant. Il est à noter que le carburant économisé dans la nouvelle stratégie de commande demeure assez faible, cependant il représente une quantité importante compte tenu du nombre de kilomètres parcourus par les véhicules hybride à travers le monde.

5.4. Conclusion

Nous avons remarqué que les résultats de la simulation dans divers scénarios de différents cycles sont satisfaisants. Cela permet d'affirmer que le contrôleur NNPC remplit bien les objectifs fixés au début. En outre, il offre des conditions de conduite flexible qui induira une disponibilité plus longue du moteur à combustion de véhicule Hybride. En outre, la consommation du carburant a été considérablement réduite lorsqu'on associe le contrôleur NNPC avec le mode logique amélioré.

Nous pouvons donc conclure que la gestion d'énergie améliorée associée au contrôleur NNPC offre des performances d'un niveau plus élevé d'optimalité. Ces résultats nous conduisent à recommander l'utilisation de cette nouvelle stratégie de commande globale afin de minimiser la consommation de carburant et réduire les émissions néfaste envers l'environnement.

Conclusion et perspectives

Conclusion82

Perspectives 83

Conclusion Générale

Le véhicule hybride s'est imposé comme solution intermédiaire qui peut durer selon les développements réalisés en termes de performance, de ce fait ce travail s'inscrit dans le cadre de la contribution à l'étude de stratégies de commande pour véhicules hybrides. Nous avons présenté les différents types d'architectures de véhicules hybrides ainsi que le simulateur HEVMBFS sur lequel nous nous sommes appuyés pour l'implémentation et la simulation des nouveaux régulateurs de vitesse; ajouté à cela la gestion d'énergie améliorée. Plusieurs composantes principales du simulateur HEVMBFS ont été détaillées, ainsi que le contrôleur classique du moteur thermique et le mode logique, ces deux derniers ont été très utiles à l'étude de comparaison des différentes techniques.

Grâce au développement des algorithmes d'apprentissages des réseaux neuronaux, la conception des modèles précis, non linéaires, statiques ou dynamiques est réalisée de manière simple et efficace sans aucune description mathématique précise. Notre première modélisation du moteur à combustion a été effectuée par un modèle neuronal, ce dernier modèle a prouvé sa robustesse, car l'introduction de la perturbation n'a eu aucun effet sur ce modèle neuronal, ainsi de bonnes performances sous différents cycles sont obtenues. Le second modèle linéaire du moteur thermique a été réalisé grâce à la méthode SUBSPACE. Ce dernier modèle et le modèle neuronal ayant fait l'objet d'application de la commande prédictive. En outre nous avons obtenu des résultats plus encourageants lors du test de la commande prédictive à base de modèle neuronal par rapport à la commande prédictive à base de modèle linéaire. Il est alors admis d'affirmer que le contrôleur NNPC offre des conditions de conduite plus

flexibles, ce qui induira une disponibilité plus longue du moteur thermique équipant le véhicule Hybride.

Afin d'obtenir la plus faible consommation de carburant, nous avons porté des améliorations notables concernant la gestion d'énergie accompagné des deux contrôleurs obtenus MPC et NNPC. Ces deux dernières méthodes et stratégies développées ont été comparées avec la stratégie de commande globale existante munie d'un régulateur PI. Il en résulte que la gestion d'énergie améliorée associée au contrôleur NNPC est la meilleure stratégie de commande globale, elle offre des performances d'un niveau plus élevé d'optimalité, ainsi que la minimisation de la consommation du carburant et la réduction des émissions néfaste envers l'environnement.

Perspectives de recherche

Les problèmes évoqués dans cette thèse et les solutions proposés ouvrent d'avantage la voie afin d'améliorer les trois parties traitées à savoir la modélisation du moteur à combustion, la commande avancée du moteur à combustion ainsi que la gestion d'énergie. En effet il sera intéressant de voir d'une part l'application des algorithmes intelligents tels que le deep learning associé à la commande MPC, d'autre part réaliser un partenariat entre les méthodes méta heuristiques et la stratégie globale d'optimisation de l'énergie.

Bibliographie

<i>Bibliographie</i>	85
----------------------------	----

Bibliographie

- [Chan, 1993] Chan CC. (1993) 'An overview of electric vehicle technology'. Proc of IEEE 1993;81(9):1202–13
- [Chau and Wong, 2001] Chau KT, Wong YS. (2001) 'Hybridization of energy sources for electric vehicles'. Energy Convers Mgmt 2001;42(9): 1059–69.
- [Wakefield, 1998] Wakefield EH. (1998) 'History of the electric automobile: hybrid electric vehicles'. Warrendale: Society of Automotive Engineers; 1998.
- [Radhi and Hussien, 2013] Radhi, R. M. Hussien, E. Q. (2013) 'Controller modelling and design of rotational speed for internal combustion engine', Thi-Qar University Journal for Engineering Sciences, Vol. 4, No. 2.
- [Harida et al., 2015] Harida M. B., Lafifi M. M., Boulebtateche B., Kermiche S., Bensaoula S. (2015) 'Model predictive control of the diesel engine for the series-parallel hybrid vehicles (HEV)'. International Conference on Automatic control, Telecommunications and Signals (ICATS15) University BADJI Mokhtar - Annaba - Algeria - November 16-18, 2015
- [De Keyser and Van Cauwenberghe, 1985] De Keyser, R.M.C. Van Cauwenberghe, A.R. (1985) 'Extended prediction self-adaptive control', Proceedings of the IFAC Symposium on Identification and System Parameter Estimation, York, UK, 1985, pp. 1317–1322.
- [Clarke et al., 1987] Clarke, D.W. Mothadi, C. Tuffs, P.S. (1987) 'Generalized predictive control. Part I—The basic algorithm and Part II—Extensions and interpretations', Automatica 23 (1987) 137–160.

- [Soeterboek, 1992] Soeterboek, R. (1992) 'Predictive Control: A Unified Approach', Prentice-Hall, Englewood Cliffs, NJ.
- [Harida et al., 2015] Harida M. B., Lafifi M. M., Boulebtateche B., Kermiche S. (2015) 'Neural network predictive control of the diesel engine for the seriesparallel hybrid vehicles (HEV)'. International Conference on Automatic control, Telecommunications and Signals (ICATS15) University BADJI Mokhtar - Annaba - Algeria - November 16-18, 2015
- [Chen et al., 1990] Chen, S. Billings, S.A. Grant, P.M. (1990) 'Non-linear system identification using neural networks', Int. J. Contr. 51 (1990) 1191–1214.
- [Liu et al. 1998] Liu, G.P. Kadiramanathan, V. Billings, S.A. (1998) 'Predictive control for non-linear systems using neural networks', Int. J. Contr. 71 (1998) 1119–1132.
- [Martinez et al., 2012] Martinez, J. S., John, R. I., Hissel, D. and Péra, M. C. (2012) 'A survey-based type-2 fuzzy logic system for energy management in hybrid electrical vehicles'. Journal Elsevier. Volume 190, Pages 192–207.
- [Nordlund, 2005] Nordlund E. (2005) 'The four-quadrant transducer system: for hybrid electric Vehicles'. PhD thesis, KTH, Royal Institute of Technology, Stockholm, 2005.
- [Xiaolai, 2006] Xiaolai He. (2006) 'Development and validation of a hybrid electric vehicle with hydrogen internal combustion engine'. PhD thesis, Texas Tech University, 2006.
- [Kermani, 2009] Kermani S. (2009) 'Gestion énergétique des véhicules hybrides: de la simulation à la commande temps réel'. PhD thesis, Université de Valenciennes et du Hainaut-Cambresis, 2009.

- [Bernardinis, 2000] Bernardinis A. d. (2000) 'Étude et optimisation d'un ensemble alternateur à aimants-redresseur commandé: application à un véhicule hybride'. PhD thesis, Vandoeuvre-les-Nancy, INPL, 2000.
- [Sigmund et al., 2014] Sigmund D., Lohner A., and Boh M. (2014) 'Simulation-based development of an energy-management-system for a drive train of a parallel hybrid electric vehicle'. In Power Electronics and Motion Control Conference and Exposition (PEMC), 2014 16th International, pages 822–827. IEEE, 2014.
- [Miller et al., 2005] Miller J. M., McCleer P. J., Everett M., Strangas E. G. (2005) 'Ultracapacitor Plus Battery Energy Storage System Sizing Methodology for HEV Power Série-parallèleElectronic CVT's', IEEE ISIE 2005, June 20-23, 2005.
- [Béranger et al., 2009] Béranger B., Chatroux D., Fernandez E., Fiette S. (2009) 'Experience feedback on electric vehicles of the French car fleet – battery impact', PCIM, Nuremberg, 2009.
- [Škugor et al., 2012] Škugor B., Pavković D. & Deur J. (2012) 'A Series-Parallel HEV Control Strategy Combining SoC Control and Instantaneous Optimisation of Equivalent Fuel Consumption', Proceedings of 2nd European Electric Vehicle Congress, Brussels, Belgium, November, 19-22.
- [Rousseau, 2008] Rousseau G., (2008) 'Véhicule hybride et commande optimale'. PhD thesis, École Nationale Supérieure des Mines de Paris, 2008.
- [Grammatico et al., 2010] Grammatico S., Balluchi A., and Cosoli E. (2010) 'A series-parallel hybrid electric powertrain for industrial vehicles'. In Vehicle Power and Propulsion Conference (VPPC), 2010 IEEE, pages 1–6. IEEE, 2010.

- [Panagiotidis et al., 2000] Panagiotidis M., Delagrammatikas G., and Assanis D. (2000) 'Development and Use of a Regenerative Braking Model for a Parallel Hybrid Electric Vehicle', SAE Technical Paper 2000-01-0995, doi: 10.4271/2000-01-0995.
- [Han et al., 2014] Han D., Wang C., Duan Y., Tian Z., Huang Z. (2014) 'An experimental study of injection and spray characteristics of diesel, and gasoline blends on a common rail injection system', Journal Elsevier.
- [Lafifi et al., 2006] Lafifi M.M., Labed F., Abassi H.A., (2006) 'Neuro Fuzzy Modelling of a Dci Diesel Engine and Fault Detection and Diagnosis', Research journal of applied sciences 1 (1-4): 45-51, 2006
- [Chen and Billings, 1992] Chen S., and Billings S. A. (1992) 'Neural Networks for nonlinear system modeling and Identification', Int. J. Control, vol. 56, no. 2, pp 319-346, Aug. 1992.
- [Narendra, 1998] Narendra K. S. (1998) 'Neural Networks for Identification and Control', Center for Systems science, Yale University, 1998.
- [Norgaard et al., 2000] Norgaard M., RaVn O., Poulsen N. K. and Hansen L. K., (2000) 'Neural Networks for Modeling and Control of Dynamic Systems', Spriger-Verlag, London 2000.
- [Pawlus et al., 2012] Pawlus W., Karimi H. R., Robbersmyr K. G. (2012) 'Data-based modeling of vehicle collisions by nonlinear autoregressive model and feedforward neural network', Journal Elsevier, 2012.
- [Sjöberg et al., 1995] Sjöberg J., Zhang J., Benveniste L., Deylon A., Glorennec B., P.Y. et al. (1995) 'Nonlinear black -box modelling in system identification: a unified overview. Automatica', 31, 1691-1724.
- [Ljung, 1999] Ljung L., (1999) 'System Identification: Theory for the User', Prentice Hall, Upper Saddle River, N.J., 2nd edition. 672p

- [Westwick and Michel, 1996] Westwick D. & Michel V., (1996) 'Identifying MIMO Wiener systems using subspace model identification methods', *Signal Processing*, Vol. 52(2), 235–258.
- [Chou and Verhaegen, 1999] Chou C.T. & Verhaegen M., (1999) 'Identification of Wiener models with process noise', In *Proceedings of the 38th IEEE Conference on Decision and Control*, Phoenix, Arizona, December, 598–603.
- [Harida et al., 2017] Harida M. B., Lafifi M. M., Boulebtateche B., Kermiche S. (2017) 'Model-Based predictive control strategy of the engine for the series-parallel hybrid vehicles (HEV)', *Rev. Sci. Technol., Synthèse* 35: 233-243 (2017)
- [Kim et al., 2009] Kim T.S. Manzie C. & Sharma R., (2009) 'Model Predictive Control of Velocity and Torque Split in a Parallel Hybrid Vehicle', *IEEE International Conference on Systems, Man and Cybernetics*, San Antonio, TX, 2014-2019.
- [Yan et al., 2012] Yan F. Wang J. & Huang K., (2012) 'Hybrid Electric Vehicle Model Predictive Control Torque-Split Strategy Incorporating Engine Transient Characteristics', *IEEE transactions on vehicular technology*, no. 6, Vol. 61, July, 2458-2467.
- [Vichik and Borrelli, 2014] Vichik S. and Borrelli F., (2014) 'Solving linear and quadratic programs with an analog circuit', *Computers & Chemical Engineering*, November, Vol. 70, 160–171.
- [Hsieh and Liu, 2016] Hsieh Y.M. & Liu Y.C., (2016) 'Model predictive control strategy for plug-in hybrid electric vehicles', *14th International Conference on Control, Automation, Robotics and Vision (ICARCV)*, Phuket, 1-6.

- [Wang et al., 2014] Wang W., Jia S., Xiang C., Huang K. & Zhao Y., (2014) 'Model predictive control-based controller design for a power-split hybrid electric vehicle, Proceedings of 2014 International Conference on Modelling', Identification and Control, Melbourne, Australia, December 3-5, 219 – 224.
- [Findeisen et al., 2006] Findeisen R., Allgöwer F. & Biegler L., (2006) 'Assessment and Future Directions of Nonlinear Model Predictive Control', Lecture Notes in Control and Information Sciences, 26. Springer. 632p.
- [Soloway and Haley, 1996] Soloway D., and Haley P.J. (1996) 'Neural Generalized Predictive Control', Proceedings of the 1996 IEEE International Symposium on Intelligent Control, 1996, pp.277–281.

Site Internet:

Le simulateur HEVMBFS peut être téléchargé gratuitement sur le site officiel de Matlab:

<https://www.mathworks.com/matlabcentral/fileexchange/28441-hybrid-electric-vehicle-model-in-simulink>

Date de la dernière consultation: 18/07/2018