

Prédiction énergétique d'un parcours automobile pour réduire la consommation de carburant des véhicules hybrides rechargeables.

M. Debert et B. Quost

21 septembre 2012

Résumé

Le contexte de cette thèse est l'optimisation de la dépense énergétique d'un véhicule hybride. Un véhicule hybride est en effet alimenté conjointement par une source d'énergie électrique et un moteur thermique traditionnel. L'utilisation judicieuse de ses ressources énergétiques consiste alors à alterner entre ces deux sources, de manière à minimiser l'émission de dioxyde de carbone en fonction de la demande énergétique lors d'un trajet. Cette demande énergétique dépend d'un grand nombre de paramètres, parmi lesquels le style de conduite du conducteur, l'environnement de conduite (urbain, autoroute ; profil altimétrique), le chargement, les conditions atmosphériques. Cependant, il n'est généralement pas possible de connaître ces paramètres pour chaque instant d'un déplacement.

L'objectif de cette thèse est de mettre en place un système de prédiction de la demande énergétique future. Le doctorant identifiera pour ce faire les variables pertinentes pour expliquer le phénomène de demande énergétique. Il proposera ensuite un modèle de prédiction de la demande énergétique. L'utilisation de techniques d'apprentissage statistique et de fusion d'informations permettra d'apprendre un tel modèle, à partir des données d'origines diverses collectées lors de la conduite du véhicule. Le doctorant étudiera par ailleurs la possibilité d'adapter le modèle en fonction des données mesurés au début d'un nouvel épisode de conduite. L'approche sera validée par le biais de tests effectués sur un véhicule équipé du système de prédiction.

1 Motivations

L'électrification des véhicules est l'une des solutions étudiées par l'industrie automobile dans le but de réduire l'impact des émissions anthropiques de dioxyde de carbone. Elle repose sur l'utilisation d'une batterie électrique, qui permet à un véhicule de rouler sans émettre de dioxyde de carbone. Cependant, l'autonomie du véhicule est alors limitée par la capacité de la

batterie. Les véhicules destinés à effectuer de longues distances doivent par conséquent être alimentés par un système hybride, faisant intervenir une ou plusieurs machines électriques et un moteur thermique traditionnel.

Une utilisation judicieuse des ressources énergétiques (électrique et thermique) permet alors de minimiser l'impact environnemental d'un déplacement. La *demande énergétique* nécessaire à ce déplacement dépend d'un grand nombre de paramètres, comme le style de conduite, l'environnement (urbain, autoroute; profil altimétrique), ainsi que diverses perturbations, propres au véhicule (chargement) ou externes (pluie, vent, densité du trafic). Si tous ces paramètres sont connus pour l'ensemble du déplacement, il est possible de déterminer un mode d'utilisation optimale des ressources énergétiques disponibles par des méthodes numériques [27, 7].

Malheureusement, dans un véhicule, il n'est pas possible de connaître parfaitement les futures conditions de roulage. De ce fait différentes techniques d'optimisation ont été embarquées dans le véhicule pour répartir au mieux la demande de puissance entre les deux sources. On peut notamment citer :

- le *contrôle heuristique*, fondé sur des règles préétablies de répartition de couple en fonction de la vitesse, du couple demandé et de l'état de charge [29, 8]. Cette stratégie présente l'avantage d'être facilement implémentable dans un véhicule mais ne garantissent pas une solution optimale. De nouvelles règles peuvent facilement être prises en compte de manière à refléter la connaissance de futures conditions de roulage.
- le *principe de Pontryagin* (cette méthode est également connue sous le nom d'Equivalent Consumption Minimisation Strategy, ou ECMS, dans la littérature). Cette stratégie s'appuie sur la résolution d'un problème d'optimisation sous contrainte par la méthode de Lagrange; l'optimalité de la solution est garantie si le multiplicateur de Lagrange est correctement choisi [9]. Des solutions ont été proposées dans le cadre de la reconnaissance de situation [10] ou de prédiction altimétrique via l'utilisation de la navigation [1].
- le *contrôle prédictif*, basé sur l'optimisation de la commande via une modélisation du système sur un horizon de prédiction [4]. Cette stratégie nécessite de fusionner un grand nombre d'informations pour avoir une prédiction fiable de la situation future (via des instruments comme des LIDAR, Navigation, communication véhicule environnement, etc).
- la *programmation dynamique stochastique*, qui repose sur une représentation stochastique des futures conditions de roulage. Cela permet de trouver la commande qui minimise la consommation en fonction de cette représentation [13, 28]. L'ajout d'informations sur les futures conditions de roulage permet d'adapter le modèle et donc d'améliorer les performances énergétiques [2].

Quelle que soit la technique choisie, la performance de ces algorithmes

reposent sur une connaissance partielle de la future demande énergétique du conducteur. Les performances des algorithmes permettant de réduire l'impact des émissions de dioxyde de carbone dépendent donc directement de la précision et de la fiabilité de ces connaissances. Il semble donc judicieux d'établir des modèles de prédiction de la demande énergétique future, en fonction des données disponibles, comme par exemple le trajet prévu via la navigation, la reconnaissance de l'environnement de conduite, ou encore la connaissance ou l'apprentissage du style de conduite du conducteur.

2 Problématique de la thèse

Cette thèse s'inscrit dans la problématique générale d'optimisation des performances énergétiques du véhicule. L'objectif est de développer une méthodologie de reconnaissance du contexte de conduite lors d'un épisode, de manière à estimer la future demande énergétique du conducteur. Ce contexte de conduite peut être défini à partir de divers paramètres :

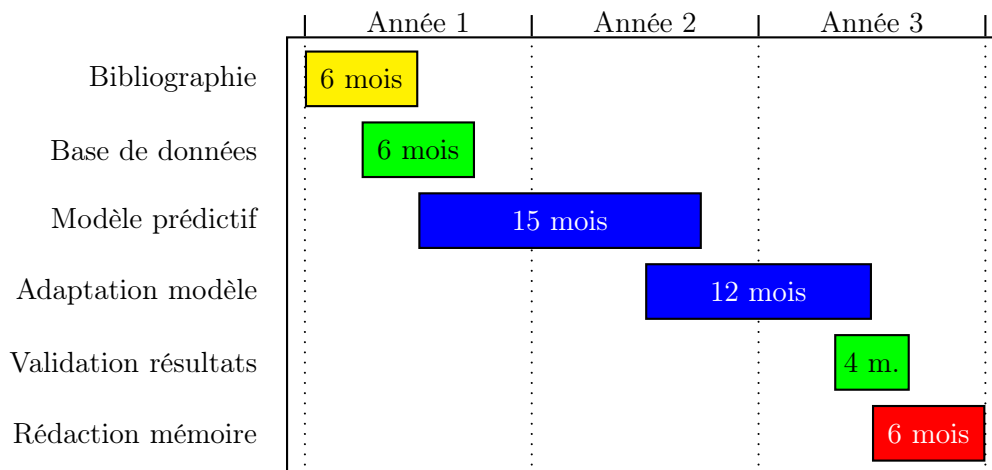
- certains propres au véhicule (ou au conducteur), comme la vitesse, la consommation instantanée ou moyenne, la sollicitation de la pédale d'accélérateur. Ces informations peuvent être obtenues via des capteurs embarqués dans le véhicule.
- certains propres à l'environnement de conduite, comme le type de voie (milieu urbain, autoroute), la vitesse maximale autorisée, la densité du trafic. Ces informations peuvent être obtenues par le biais de sources d'information externes : cartes, canaux d'informations (conditions météorologiques, infotrafic).

Les verrous technologiques et scientifiques sont multiples. Tout d'abord, on peut souligner la très grande diversité des données disponibles. De plus, un certain nombre d'informations sont caractérisées par un aspect temporel : une valeur de consommation instantanée n'a en effet que peu de sens si elle est considérée indépendamment des valeurs qui la précèdent. En outre, les informations peuvent dépendre fortement du contexte de conduite : les variations de consommation seront évidemment différentes selon que le véhicule se trouve sur l'autoroute ou en milieu urbain. Par ailleurs, les données peuvent être entachées d'imprécision : par exemple, la densité du trafic peut n'être connue que de manière partielle (trafic fluide, dense, bouchons). Elles sont également incertaines : les capteurs embarqués dans le véhicule peuvent connaître des dysfonctionnements, tout comme les prévisions météorologiques ou des conditions de trafic à long terme peuvent s'avérer erronées. Notons que la fiabilité d'une source d'informations peut elle aussi dépendre du contexte de conduite. Enfin, les sources d'informations peuvent être temporairement indisponibles, par exemple à cause d'un capteur défaillant, ou de la perte du signal GPS.

La multiplicité des sources d'informations et leur interdépendance, et la nécessité de prendre en compte leur redondance, suggèrent la mise en place d'un système de décision structuré par combinaison de multiples sources d'information. Ainsi, on pourra entraîner un classifieur [20, 6] à identifier le profil de conduite du conducteur à partir des informations fournies par les capteurs embarqués dans le véhicule. Lors d'un épisode de conduite, le modèle appris pourra ensuite être adapté « en ligne », au moyen des données recueillies lors des premiers instants de cet épisode. La prise en compte du caractère temporel des données au moyen de processus stochastiques [15, 23] sera également étudiée. Les sorties du classifieur pourront ensuite être fusionnées [22, 30, 11, 14, 21] avec les autres sources d'information disponibles, de manière à déterminer le mode de dépense énergétique optimal. Pour ce faire, l'utilisation de la théorie des fonctions de croyance [24, 26, 25] semble particulièrement adapté. Ce formalisme de gestion des connaissances imprécises et incertaines comporte en particulier de nombreux outils théoriques pour la fusion de sources d'informations [16, 12, 18, 5, 19], en particulier dans le cas de sources non indépendantes [3]. Le choix de ce cadre théorique est également motivé par le caractère contextuel des données. Il permet également de prendre en compte le degré de fiabilité des sources au moyen de l'opérateur d'affaiblissement [26, 17]. Soulignons enfin que l'intérêt de la théorie des fonctions de croyance pour l'apprentissage de modèles en présence de données imprécises et incertaines a récemment été démontré [3].

3 Planning du doctorant

1. Bibliographie.
2. Base de données d'apprentissage et de test : identification des variables pertinentes pour la prédiction du contexte de conduite (profil de vitesse, altimétrie, météorologie, etc), et création d'une base de données à partir des mesures collectées lors de différents essais.
3. Élaboration d'un modèle de prédiction des futures conditions de roulage.
4. Étude de l'adaptation de ce modèle en fonction des conditions réellement rencontrées.
5. Validation des résultats : mesure de la réduction de consommation sur un véhicule équipé du système de prédiction.
6. Rédaction du mémoire de thèse.



4 Conditions d'encadrement

Le financement CIFRE de la thèse sera pris en charge par Renault. Le doctorant sera basé au Technocentre (1, avenue du Golf, 78288 Guyancourt). L'encadrement sera effectué conjointement par Maxime Debert (Ingénieur de recherche, Renault), Thierry Denceux (Professeur, UTC, Heudiasyc) et Benjamin Quost (Maître de conférences, UTC, Heudiasyc).

5 Contacts

Maxime DEBERT
Ingénieur contrôle des systèmes
Supervision Véhicules Électriques et Véhicules Hybrides
Équipe DELTA — Service Synthèse et Contrôle des Systèmes
(+33)1 76 85 03 44
maxime.debert@renault.com

Benjamin QUOST
Maître de conférences, département Génie Informatique
Laboratoire Heudiasyc
Université de Technologie de Compiègne
(+33)3 44 23 49 68
benjamin.quost@utc.fr

Références

- [1] D. Ambühl and L. Guzzella. Predictive reference signal generator for hybrid electric vehicles. *IEEE transactions on vehicular technology*, 2009.
- [2] K. Aouchiche, F. Bonnans, G. Granato, and H. Zidani. A stochastic dynamic principle for hybrid systems with execution delay and decision lags. *Decision and Control and European Control Conference (CDC-ECC), 2011 50th IEEE Conference on*, pages 6788–6793, 2011.
- [3] M.-H. Masson B. Quost and T. Dencœux. Classifier fusion in the dempster-shafer framework using optimized t-norm based combination rules. *International Journal of Approximate Reasoning*, 52(3) :353–374, 2011.
- [4] M. Back. *Prädiktive Antriebsregelung zum energieoptimalen Betrieb von Hybridfahrzeugen*. PhD thesis, Universitätsverlag karlsruhe, 2005.
- [5] Y. Bi, J. Guan, and D. Bell. The combination of multiple classifiers using an evidential reasoning approach. *Artificial Intelligence*, 172(15) :1731–1751, October 2008.
- [6] Christopher M. Bishop. *Pattern Recognition And Machine Learning*. Springer, 2006.
- [7] S. Delprat, J. Laubert, T.M. Guerra, and J. Rimaux. Control of a parallel hybrid powertrain : optimal control. *IEEE transaction on vehicle technology*, 53(3) :872–881, 2004.
- [8] C. Forgez, G. Friedrich, and J.M. Biedinger. Système flou de supervision des modes de fonctionnement d’un véhicule hybride parallèle. 2000.
- [9] L. Guzzella and A. Sciarretta. *Vehicle Propulsion Systems Introduction to Modeling and Optimization second edition*. Springer, 2007.
- [10] S. Jeon, S. Jo, Y. Park, and J. Lee. Multi-mode driving control of a parallel hybrid electric vehicle using driving pattern recognition. *ASME Journal of dynamic system, mesurement, control*, 124 :141–149, 2002.
- [11] L. Kuncheva, J. Bezdek, and R. Duin. Decision templates for multiple classifier fusion : an experimental comparison. *Pattern Recognition*, 34(2) :299–314, 2001.
- [12] C.A. Le, V.-N. Huynh, A. Shimazu, and Y. Nakamori. Combining classifiers for word sense disambiguation based on Dempster-Shafer theory and OWA operators. *Data and Knowledge Engineering*, 63(2) :381–396, 2007.
- [13] C.C. Lin. *Modelling and control strategy development for hybrid vehicles*. PhD thesis, University of Michigan, 2004.
- [14] E.J. Mandler and J. Schurmann. Combining the classification results of independent classifiers based on Dempster-Shafer theory of evidence. *Pattern Recognition and Artificial Intelligence*, 10 :381–393, 1988.

- [15] Xiaoning Meng. Human driving behavior recognition based on hidden markov models. In *IEEE International Conference on Robotics and Biomimetics (ROBIO'06)*, pages 274–279, 2006.
- [16] D. Mercier, G. Cron, T. Denoeux, and M. Masson. Fusion of multi-level decision systems using the Transferable Belief Model. In *Proceedings of FUSION'2005*, Philadelphia, USA, 2005.
- [17] D. Mercier, B. Quost, and T. Dencœux. Refined modeling of sensor reliability in the belief function framework using contextual discounting. *Information Fusion*, 9(2) :246–258, 2008.
- [18] B. Quost, T. Dencœux, and M.-H. Masson. Pairwise classifier combination using belief functions. *Pattern Recognition Letters*, 28(5) :644–653, April 2007.
- [19] M. Reformat and R. Yager. Building ensemble classifiers using belief functions and OWA operators. *Soft Computing*, 12(6) :543–558, 2008.
- [20] Peter E. Hart Richard O. Duda. *Pattern Classification*. John Wiley and Sons, London, UK, 1973.
- [21] G. Rogova. Combining the results of several neural network classifiers. *Neural Networks*, 7(5) :777–781, 1994.
- [22] D. Ruta and G. Gabrys. Classifier selection for majority voting. *Information Fusion*, 6(1) :63–81, 2005.
- [23] A. Sathyanarayana. Human driving behavior recognition based on hidden markov models. In *IEEE International Conference on Vehicular Electronics and Safety (ICVES 2008)*, pages 276–281, 2008.
- [24] G. Shafer. *A mathematical theory of evidence*. Princeton University Press, Princeton, NJ, 1976.
- [25] P. Smets. Data fusion in the Transferable Belief Model. In *Proceedings of the 3rd International Conference on Information Fusion (Fusion'00)*, pages 21–33, Paris, France, 2000.
- [26] P. Smets and R. Kennes. The Transferable Belief Model. *Artificial Intelligence*, 66(2) :191–234, 1994.
- [27] O. Sunström, D. Ambühl, and L. Guzzella. On implementation of dynamic programming for optimal control problems with final state constraints. *Oil & Gas Science and technology*, 65 :91–102, 2010.
- [28] E. D. Tate. *Technique for hybrid electric vehicle controller synthesis*. PhD thesis, University of Michigan, 2007.
- [29] A. Vaccaro and D. Villaci. Prototyping of a fuzzy based energy manager for parallel hybrid electric vehicles. *ELE-Drive Transportation*, 2004.
- [30] L. Xu, A. Krzyzak, and C. Y. Suen. Methods of combining multiple classifiers and their applications to handwriting recognition. *IEEE Transactions on System, Man and Cybernetics*, 22 :418–435, 1992.