

Détection de l'état d'un opérateur humain dans le contexte de la conduite ferroviaire.

Driver's state detection in railway systems

N.D. Rachedi; D. Berdjag; F. Vanderhaegen

LAMIH - CNRS UMR 8201

Université de Valenciennes et du Hainaut-Cambrésis, Le mont Houy, 59313 Valenciennes cedex 9.

nedjemi.rachedi;denis.berdjag;frederic.vanderhaegen@univ-valenciennes.fr

Résumé :

Cet article s'intéresse au diagnostic de l'état des conducteurs de systèmes de transports ferroviaires. Il s'agit d'observer les comportements de conduite, de les identifier et de détecter un état particulier du conducteur : la somnolence par exemple ou la nervosité.

La méthode proposée détecte les états du conducteur en utilisant une information à priori sur la personnalité du conducteur (son degré de recherche de sensations) ainsi que des mesures provenant de capteurs non intrusifs équipant le système Homme-Machine, notamment la mesure de la vitesse du train et la mesure du temps de réaction du conducteur. Les comportements de conduite de l'opérateur humain sont modélisés sous la forme de « Chaînes Cachées de Markov ». Ces comportements sont analysés et comparés à des modèles de référence afin de les qualifier en « normaux » ou « anormaux ». Afin de pallier les effets d'incertitudes induites par les mesures et la modélisation, un réseau Bayésien est construit pour aider à la décision et déterminer l'état actuel du conducteur. La contribution principale de notre approche proposée est de permettre une détection fiable et non intrusive des états « dangereux » en proposant une méthode de fusion de données hétérogènes et incertaines. Un exemple est traité en illustration.

Summary:

This paper deals with driver's state diagnosis in rail transportation systems. Driving behaviors are observed and identified, in order to detect driver's drowsiness or nervousity. The detection method uses the a priori knowledge of driver's sensation seeking level as well as measurements from nonintrusive sensors equipping the Human-Machine system, including train's speed measurement and driver's reaction time measurement. The driving behaviors of the human operator are modeled in the form of 'hidden Markov Models'. These behaviors are analyzed and compared to reference models in order to qualify them as being "normal" or "abnormal". Uncertainty effects induced by measurements and modeling are mitigated using a Bayesian network in order to accurately and robustly determine the driver's state. The main contribution of the proposed approach is to enable a reliable and nonintrusive detection of "dangerous" states using appropriate fusion of the heterogeneous and uncertain acquired data. An example is given to illustrate the approach.

1. Introduction :

La sûreté d'un système de transport de passagers est une problématique très actuelle. Deux aspects sont spécifiquement traités : la robustesse du système technologique aux contraintes et aux perturbations de l'environnement d'exploitation et la résilience du système Homme-Machine vis-à-vis des erreurs humaines et des situations imprévues. Dans le cadre de cette seconde thématique, le diagnostic d'un système Homme-Machine évoluant dans un environnement dynamique est un défi à relever. La modélisation de l'interaction homme-machine-environnement est particulièrement difficile, car elle doit décrire des évolutions déterministes et non-déterministes (stochastiques) dans un contexte où l'information disponible sur le système est incertaine ou même incomplète.

Les études dans le domaine de transport montrent que la probabilité d'erreur humaine augmente avec la baisse d'attention et de vigilance du conducteur. Ces deux facteurs sont reconnus parmi les principales causes pouvant augmenter les risques d'accident de transport routier ou ferroviaire (Bonfond et al., 2006). Néanmoins, les systèmes destinés à pallier les risques liés aux défaillances du conducteur qui sont utilisés actuellement tels que la veille automatique à contrôle de maintien d'appui (VACMA) ne permettent pas de détecter un comportement ou un état « indésirable » du conducteur. Ces systèmes servent plutôt à détecter l'inconscience du conducteur. Ils sont aussi assez mal acceptés par les conducteurs (Foot et al., 2008).

Dans la littérature, les approches de détection de l'hypovigilance, de la fatigue ou de l'inattention sont classées selon le type de sources de données utilisées pour évaluer l'état de l'humain : on distingue les données provenant des sources directes (Qiang et al., 2002, Chin-Teng et al., 2005), des données provenant de sources indirectes (Igarashi et al., 2004, Krajewski et al., 2009). Les sources directes sont les mesures des activités physiologiques ou physiques de l'opérateur humain telles que le rythme cardiaque, l'activité cérébrale, les mouvements de la tête, la vitesse de clignement des yeux... etc. Les sources indirectes sont les mesures provenant du système technologique (la vitesse, les entrées d'accélération ou de freinage... etc.) que l'opérateur contrôle. Les caractéristiques d'évolution de ces données permettent d'interpoler l'état de l'humain qui les contrôle, par exemple des évolutions saccadées étayeront l'hypothèse d'une nervosité accrue de l'opérateur. Il existe également une catégorie d'approches qui combinent les sources directes et indirectes (Liang et al., 2007). En outre, des traits de personnalité du conducteur tels que le degré de recherche de sensation ou de susceptibilité à l'ennui ont une certaine influence sur sa performance et sa vigilance (Verwey et al., 2000, Oppenheim et al., 2010).

Les capteurs mesurant l'activité physiologique sont très fiables (Dong et al., 2011) mais sont considérés intrusifs, assez encombrants et sont souvent mal acceptés par les opérateurs humains. Pour réaliser un système de détection acceptable et performant, il faut envisager l'utilisation des mesures directes et indirectes combinées, car cela permet de réduire le taux de fausses alarmes et augmenter la vitesse de détection (Dong et al., 2011).

Notre objectif est le développement d'un système de détection non intrusif, capable de mesurer, d'interpréter les symptômes de dégradation de la conduite et à partir de là d'inférer l'état du conducteur. Ce système doit aussi avoir un coût raisonnable et assurer un certain degré d'acceptabilité sociale.

À cet effet, une approche de détection basée sur la construction des modèles Chaînes Cachées de Markov (CCM) est proposée. Cette approche utilise la mesure discrétisée d'un paramètre continu provenant du système technologique. L'évolution de cette mesure permet de

distinguer des comportements de conduite « normaux » des comportements « anormaux », en comparant cette évolution à des images d'évolutions types associées aux comportements de référence à détecter.

Pour permettre une détection plus performante et robuste dans toutes les conditions d'exploitation, une mesure provenant du conducteur ainsi qu'une information sur sa personnalité sont associées avec les modèles CCM.

Compte tenu des incertitudes inhérentes aux mesures ainsi que l'hétérogénéité de ces données, un réseau Bayésien (RB) combinant ces données est utilisé pour l'aide à la décision et la détection de l'état éventuel du conducteur. Le système proposé infère et détecte l'état du conducteur en suivant les étapes décrites sur la Figure 1.

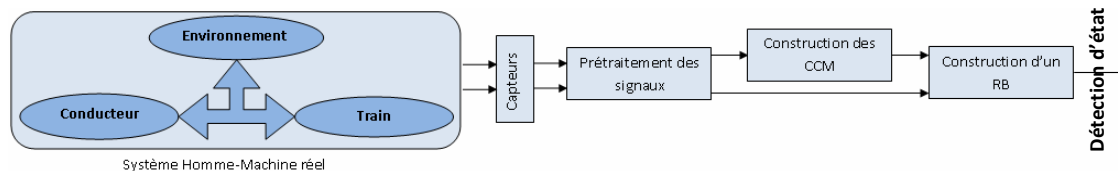


Figure 1. Méthodologie de détection

L'article est organisé de la manière suivante: la première section introduit le contexte du travail et la méthodologie proposée. La deuxième section présente le système de diagnostic. Les aspects théoriques des CCM et des RB et leurs applications dans notre contexte sont présentés dans la troisième section. La section suivante exploite le système de diagnostic en simulation afin de montrer ses performances. Finalement, dans la dernière section, une conclusion est donnée et quelques perspectives sur des travaux futurs sont présentées.

2. Présentation générale du système de diagnostic :

Afin de détecter l'état du conducteur, un modèle représentant la relation et l'interaction entre le triplet (Train, Conducteur, Environnement) est nécessaire. La cinématique du train est fonction des décisions ou des attitudes du conducteur (accélérer, décélérer, ... etc.). Ces décisions sont relatives à des événements intérieurs et extérieurs au conducteur tels que les changements dans son environnement (apparition d'une intersection ou d'un stop... etc.) mais aussi à ses états émotionnels et physiologiques (colère, stress, fatigue... etc.).

Les états émotionnels du conducteur ne sont jamais directement mesurables. En outre, il est plus simple d'observer un comportement qu'un état émotionnel.

À cet effet, nous commençons par détecter un comportement pour inférer par la suite un état. Pour détecter les comportements, la méthode consiste à observer l'évolution des variables cinématiques du système technologique, les plus faciles à observer telles que la vitesse du train, et les comparer à des évolutions types caractérisant des comportements de conduite connus. La finalité de cette comparaison est de déduire le comportement de conduite.

Notre approche est similaire à celle traitée dans (Gadepally et al., 2011), où les auteurs utilisent la dynamique du véhicule pour détecter les actions du conducteur durant la conduite d'un véhicule automobile dans une intersection.

L'approche proposée dans cet article se base sur l'hypothèse que chaque état du conducteur induit une manière de conduite particulière. Cela veut dire qu'à chaque état du conducteur est associé un profil spécifique d'évolution de la variable vitesse (Figure 2).

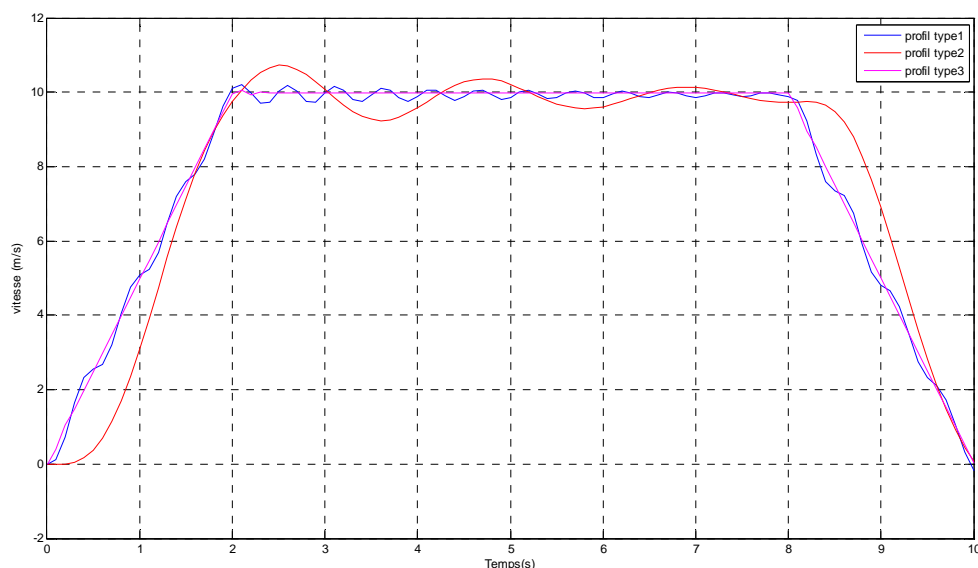


Figure 2. Profil de vitesse de chaque état comportemental du conducteur

Le scénario d'étude consiste à démarrer le train en réponse à un signal de départ et de s'arrêter à la position d'arrêt avec une unique limitation de vitesse pendant le parcours. Cela implique que le conducteur doit suivre un profil de vitesse trapézoïdal. L'échelle du temps et de l'amplitude des profils de vitesse représentés sur les différentes figures est normalisée.

Le conducteur caractérisé par le premier type de profil aura tendance à franchir les limitations de vitesse et s'arrêter en général, donc il essaiera de corriger les franchissements d'une manière assez rapide en montrant une certaine impatience.

Le conducteur caractérisé par un profil du deuxième type aura du mal à maintenir sa vitesse constante ; la vitesse déviara lentement de la normale. Le conducteur va tenter de corriger la vitesse, mais puisque sa vigilance est faible, son profil sera caractérisé par de longues dérives.

Le conducteur caractérisé par le troisième profil respectera les limitations de vitesse et sera capable de maintenir sa vitesse constante suivant la consigne en cours.

Pour modéliser ces comportements de conduite, les Chaînes Cachées de Markov sont utilisées. Ce choix est justifié par le fait que les CCM permettent de représenter des problèmes où les états ne sont pas directement observables. En effet, Une CCM est un modèle stochastique, ce qui est approprié à la nature non déterministe du comportement des conducteurs. Ces performances sont liées à l'état émotionnel (ou l'intention) du conducteur qui est caché et à son action résultante (ou son comportement) qui peut être mesurée.

Donc une CCM est construite pour chaque comportement du conducteur. La structure de chaque CCM est déterminée par un apprentissage à partir des mesures de la vitesse du train pendant le parcours du scénario d'étude. Cet apprentissage se fait hors ligne, mais la détection du comportement de conduite se fait en ligne.

Pour la construction des modèles CCM, le prétraitement des données est nécessaire. Il s'agit d'échantillonner à intervalle de temps régulier les courbes de vitesse de chaque conducteur et faire par la suite une extraction de caractéristiques. La méthode d'extraction repose sur le calcul du sinus de l'angle formé entre la droite passant par le point précédent et par le point courant et l'axe horizontal. Le sinus de l'angle obtenu est arrondi à 0,1 près. Cette méthode est inspirée des méthodes de reconnaissance d'écriture (Rigoll et al., 1996).

L'ensemble des observations extraites à partir des courbes de vitesse constitue l'ensemble des émissions des modèles CCM. Cet ensemble contient des entiers entre 1 et 20.

Afin de reconnaître l'état d'un conducteur quelconque par son comportement de conduite, les mêmes prétraitements et extractions de caractéristiques sont effectués sur les données acquises durant un parcours de conduite. La séquence d'observations obtenue par l'extraction de caractéristiques est alors comparée aux chaînes de Markov cachées associées aux trois profils de référence.

Après avoir calculé les probabilités que le conducteur soit dans l'un des états à partir du profil de vitesse observé, il est assumé que l'état avec la probabilité la plus élevée est l'état réel du conducteur. Cependant, la possibilité d'erreur subsiste dans certains cas d'étude où les probabilités d'appartenance sont proches. Pour le départage et la fiabilisation de la détection, deux données supplémentaires sont utilisées. La première donnée est une information sur la personnalité du conducteur, qui est sa tendance a priori à rechercher des sensations. La deuxième est une mesure directe non intrusive provenant du conducteur : son temps de réaction à une tâche secondaire appelée tâche de vigilance psychomotrice. Cette tâche est une alerte artificielle déclenchée afin d'obtenir une réponse du conducteur. Le stimulus peut être un signal sonore ou visuel.

Ces informations sont fusionnées en utilisant un réseau bayésien. Ce choix est justifié par la nature hétérogène des données, ainsi que les incertitudes inhérentes aux mesures liées à l'environnement dynamique où le système Homme-Machine étudié évolue.

3. La théorie et l'application des Chaînes Cachées de Markov et du Réseau Bayésien:

3.1. Les Chaînes Cachées de Markov :

Une Chaîne Cachée de Markov est un modèle statistique représentant un processus stochastique comportant N états inobservables. Ce processus vérifie la propriété de Markov, à savoir : « Sachant le présent, le futur est indépendant du passé ». Une CCM est définie par un quintuplet $\Lambda = (\Sigma, \Omega, \Pi, A, B)$ où :

- Le vecteur $\Pi = \{\pi_i = P(s_i)\}$ regroupe les probabilités initiales des états cachés.
- L'ensemble $\Sigma = \{s_1, \dots, s_N\}$ contient les états cachés de la chaîne.
- La matrice $A = \{a_{ij} = P(s_j | s_i)\}$ décrit les probabilités de transitions entre les états cachés.
- L'ensemble $\Omega = \{o_1, \dots, o_M\}$ contient les symboles émis par les états s_i de la CCM.
- La matrice $B = \{b_i(o_k) = P(o_k | s_i)\}$ décrit les probabilités d'émission ou d'observation.

Un exemple simple d'une CCM est donné Figure 4.

3.2. Le Réseau Bayésien:

Les réseaux bayésiens sont des modèles de représentation de connaissances combinant les approches probabilistes et la théorie de graphes. Ils permettent de représenter des situations de raisonnement probabiliste à partir de connaissances incertaines. Les RB sont utilisés dans le diagnostic des systèmes, l'analyse et la fusion de données, l'aide à la décision et le contrôle des systèmes (Naïm et al., 2004). Les RB ont été également utilisés dans la surveillance de la fatigue de l'être humain (Qiang et al., 2006).

Définition (Naïm et al., 2004)

Un réseau bayésien est un modèle probabiliste graphique défini par:

- Un graphe acyclique orienté $G, G = (V, E)$ où V est l'ensemble des nœuds de G , et E l'ensemble des arcs de G .
- Un espace probabilisé fini (Ω, Z, P) .
- Un ensemble de variables aléatoires associées aux nœuds du graphe et définies sur (Ω, Z, P) , tel que :

$$P(V_1, V_2, \dots, V_n) = \prod_{i=1}^n P(V_i | C(V_i)) \text{ , où } C(V_i) \text{ est l'ensemble des causes (parents) de } V_i \text{ dans le graphe } G.$$

Afin de modéliser les connaissances par un RB, deux approches sont généralement utilisées. La première approche est dite qualitative. Elle est basée sur la théorie des graphes et consiste à construire le RB (nœuds et arcs) en utilisant la notion de causes à effets.

La seconde approche est dite quantitative. Elle consiste à associer à chaque nœud une table de probabilité qui le caractérise.

Donc après avoir construit un RB, l'inférence repose sur la propagation de l'information au sein du réseau, c'est-à-dire les calculs de probabilités a posteriori de certaines variables à partir d'observations sur d'autres variables.

3.3. Application des CCM et du RB dans la détection des états du conducteur :

On associe un CCM Λ_i / $i = 1, 2, 3$, à chaque profil de vitesse du conducteur. Chaque CCM contient cinq états cachés et 20 sorties (voir Figure 3.a.).

Afin de fixer les paramètres de chaque CCM (matrice A, matrice B et vecteur Π), l'algorithme de 'Baum-Welch' est utilisé pour la phase d'apprentissage (Rabiner, 1989).

Après que l'acquisition de la vitesse du conducteur est faite, ainsi que la phase du prétraitement, on identifie le comportement de conduite. L'identification consiste à estimer la probabilité que la séquence d'observation est celle générée par l'une des CCM (voir Figure 3.b). L'estimation des probabilités est faite suivant l'algorithme 'Forward-Backward' (Rabiner, 1989).

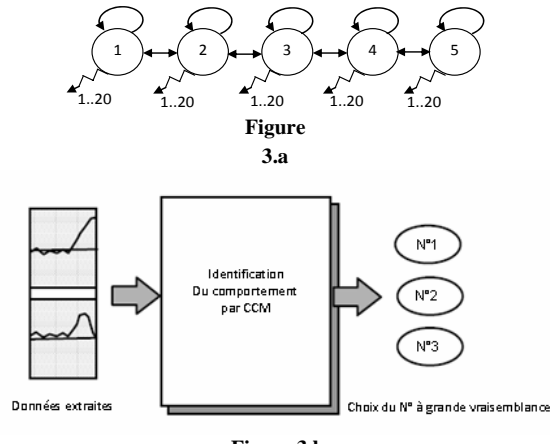


Figure 3. Structure des CCM proposés et leur utilisation

Le RB proposé exploite trois informations : la probabilité que le conducteur soit dans l'un des états comportementaux (calculée précédemment à partir des CCM), le temps de réaction du même conducteur à une alerte artificielle et son degré de recherche de sensation.

Le temps de réaction du conducteur est mesuré, puis normalisé et classé en trois catégories:

- Petit si la valeur est dans $[0, 0,2[$,
- Moyen si la valeur est dans $[0,2, 0,7[$,
- Grand si la valeur est dans $[0,7, 1]$.

Le degré de recherche de sensation chez le conducteur est une mesure subjective, obtenue à partir d'un questionnaire. Ce degré est classé en trois catégories : Petit, Grand et Moyen.

Le réseau bayésien présenté est formé de trois nœuds parents (correspondant aux trois données) et un nœud enfant statuant l'état du conducteur. Le RB est représenté sur la Figure 4.

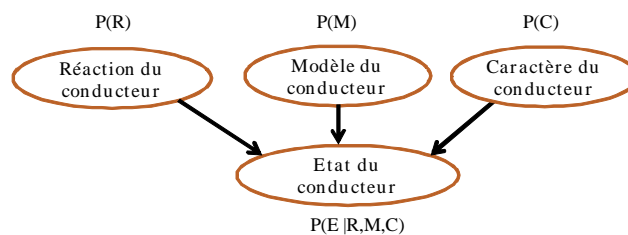


Figure 4. Réseau Bayésien proposé

Les trois comportements de conduites (n°1, n°2 et n°3) sont hypothétiquement assimilés respectivement : Au comportement surréactif, au comportement hypovigilant et au comportement normal.

Le nœud 'Etat du conducteur' comprend trois états à savoir : état surréactif, état hypovigilant et état normal.

Nous présentons l'une des tables de probabilités des nœuds parents, à savoir 'réaction du conducteur' dans la table 1 :

Réaction du conducteur	P(R)
Petit	0.333
Moyen	0.334
Grand	0.333

Table 1. Probabilité marginale P(R).

La probabilité conditionnelle du nœud état du conducteur en sachant que son degré de recherche de sensation est Grand ' $P(E | R, M, C=G)$ ' est donnée dans la table 2:

Réaction du conducteur	P			M			G		
Modèle du conducteur	A	N	H	A	N	H	A	N	H
A_m	0.7	0.1	0	0.45	0	0	0.2	0.1	0
N_m	0.3	0.9	0.5	0.55	0.8	0.3	0.3	0.4	0.1
H_m	0	0	0.5	0	0.2	0.7	0.5	0.5	0.9

Table 2. Probabilité conditionnelle $P(E | R, M, C=G)$.

Légende: A_m: Comportement de conduite Surréactif, N_m: Comportement de conduite Normal, H_m: comportement de conduite Hypovigilant, P: Petit, M: Moyen, G: Grand, E: état Agité, N: état Normal, H: état Hypovigilant.

Après avoir estimé la probabilité que le conducteur ait l'un des comportements d'intérêt, l'information est instanciée dans le nœud 'Modèle du conducteur' du RB. Le temps de réaction du conducteur est instancié également dans le nœud 'Réaction du conducteur'. Le degré de recherche de sensation est instancié dans le nœud 'Caractère du conducteur'. À partir de ces informations, l'état du conducteur est évalué et exprimé en termes de probabilités dans le nœud 'état du conducteur' du RB.

4. Tests et Résultats de la méthodologie de détection d'état du conducteur dans le domaine ferroviaire :

Dans le but de tester la méthodologie, une série de test a été effectuée. Afin de détecter l'état du conducteur, nous commençons par classer le comportement de conduite (normal, hypovigilant, surréactif), des profils de vitesse ont été enregistrés et évalués par les CCM.

L'un des scénarios de test est un parcours à cinq stations, où le conducteur démarre après un signal de départ et s'arrête dans la prochaine station pour démarrer une autre fois. Le conducteur doit respecter les limitations de vitesse pendant son parcours. La vitesse du conducteur, la limitation de vitesse ainsi que le découpage en fenêtre de détection sont représentés dans la figure 5.

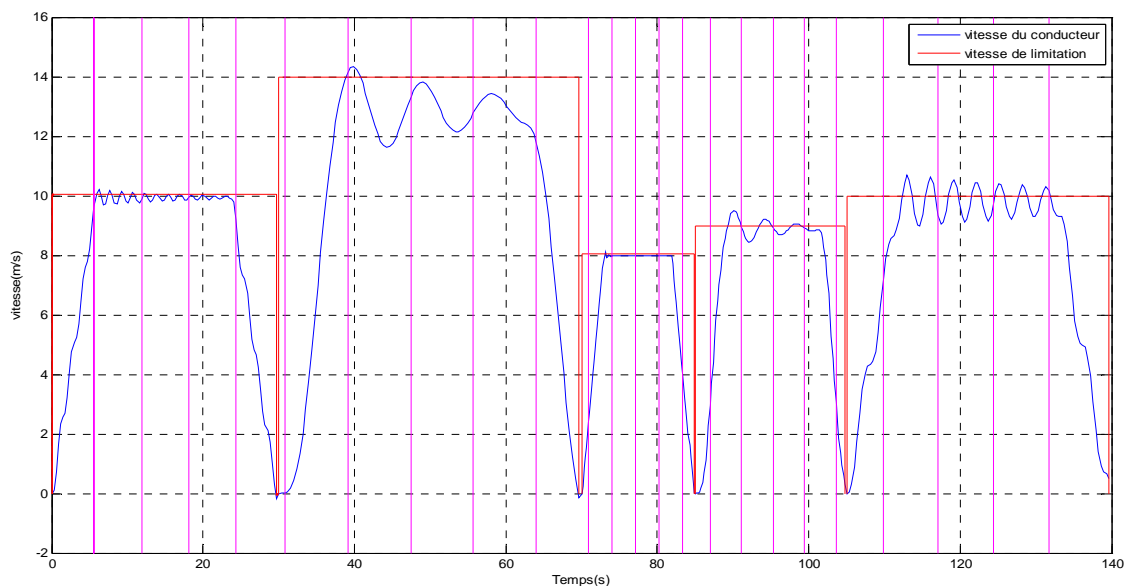


Figure 5. Détection de comportement du conducteur dans un parcours de conduite

Les résultats de détections de comportement du conducteur sont donnés en termes de logarithme de vraisemblance, ils sont donnés dans le tableau suivant :

Logarithme de vraisemblance	Comportement Hypovigilant	Comportement Surréactif	Comportement Normal
Fenêtre 1	-110.3901	-19.7598	-50.6327
Fenêtre 2	-165.3053	-56.7198	-Inf
Fenêtre 3	-83.6169	-67.7722	-Inf
Fenêtre 4	-63.4954	-62.7124	-Inf

Fenêtre 5	-156.6899	-43.8915	-112.4432
Fenêtre 6	-93.9651	-14.3059	-14.5344
Fenêtre 7	-77.8921	-37.6788	-Inf
Fenêtre 8	-83.7961	-62.1267	-147.3998
Fenêtre 9	-74.2595	-61.3966	-Inf
Fenêtre 10	-208.7578	-27.1266	-89.7904
Fenêtre 11	-207.7043	-35.9892	-44.1868
Fenêtre 12	-75.0009	-63.1197	-26.3793
Fenêtre 13	-67.0561	-62.4322	-15.3661
Fenêtre 14	-46.4259	-42.3464	-15.4611
Fenêtre 15	-188.0077	-53.8601	-103.8748
Fenêtre 16	-199.4602	-37.4339	-Inf
Fenêtre 17	-133.4104	-66.9361	-Inf
Fenêtre 18	-67.3807	-74.5982	-90.1513
Fenêtre 19	-33.1377	-44.5780	-Inf
Fenêtre 20	-230.0860	-35.5200	-95.4898
Fenêtre 21	-270.3605	-26.1981	-40.0213
Fenêtre 22	-181.5501	-32.0579	-70.8310
Fenêtre 23	-258.6792	-38.7019	-Inf
Fenêtre 24	-161.5400	-47.8447	-Inf

Table 3. Résultats de détection de comportement par les CCM

Le comportement de conduite le plus probable est choisi c'est-à-dire celui qui possède la plus grande valeur du logarithme de vraisemblance.

Sur l'ensemble des tests de la détection du comportement par CCM, on obtient un taux de fausse alarme de 16 %. Afin de réduire ce taux et d'éviter les situations de confusion telles que dans la fenêtre 6 où les logarithmes de probabilité d'appartenance au comportement agité et au comportement normal sont presque égaux on utilise le RB de la figure 4.

Les logarithmes de vraisemblance sont recalculés en termes de probabilités. L'information de la probabilité du comportement est instanciée dans le RB ainsi que le temps de réponse du conducteur et son degré de recherche de sensation

On présente dans la Figure 6 le résultat de détection de l'état conducteur pendant la fenêtre 6. Le temps de réaction du conducteur pendant cette période est mesuré et classé dans la catégorie 'moyen', son degré de recherche de sensation est jugé petit.

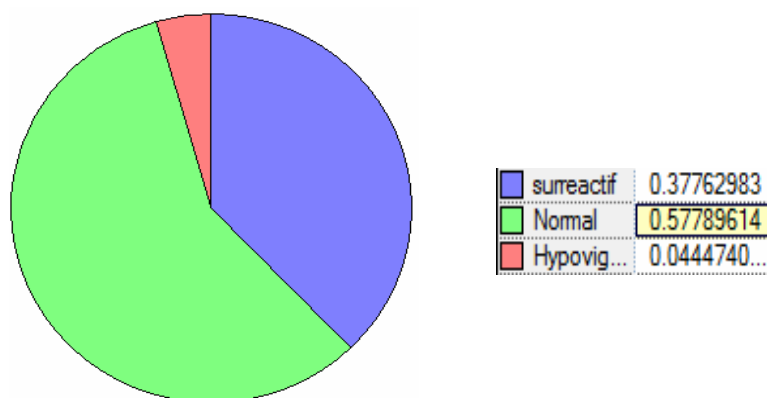


Figure 8. Résultat de détection d'état du conducteur par le RB.

Après inférence le RB détecte un état émotionnel à 51,78 % 'Normal' du conducteur, cela nous permet de dire qu'en utilisant le RB on a pu effectuer une détection de l'état émotionnel du conducteur à partir de l'information incertaine et incomplète obtenue à partir des CCM et de l'information caractère et temps de réaction du conducteur.

5. Conclusion:

Dans cet article, une approche de détection de l'état de conducteurs de systèmes ferroviaires est proposée. La méthodologie de détection de l'état employée est faite en deux étapes. La première est basée sur la construction des modèles de chaînes cachées de Markov, ce qui permet l'identification de comportement du conducteur. La deuxième étape utilise un réseau bayésien intégrant la décision de détection de l'état, ce qui permet de garder une détection fiable nonobstant des mesures hétérogènes et entachées d'incertitudes.

Pour de futurs travaux, l'utilisation d'autres sources d'information endogènes ou exogènes au conducteur telles que l'oculomètre ou la caméra est envisagée. L'objectif est d'améliorer l'approche de détection en multipliant les possibilités de discrimination des données observées. Par ailleurs, la validation l'approche sur le simulateur de conduite ferroviaire 'ILLUSIO' du LAMIH à Valenciennes est programmée.

Références:

- [1] A. Bonnefond et al., 2006, Behavioral Reactivation and Subjective Assessment of the State of Vigilance, *International Journal of Occupational Safety and Ergonomics (JOSE)*, Vol. 12, No. 3, 221–229.
- [2] L. Chin-Teng et al., 2005, EEG-Based Drowsiness Estimation for Safety Driving Using Independent Component Analysis, *IEEE transactions on circuits and systems I: regular papers*, vol. 52, no. 12.
- [3] I. G. Daza et al., 2011, Drowsiness monitoring based on driver and driving data fusion, 14th International IEEE Conference on Intelligent Transportation Systems Washington.
- [4] Y. Dong et al., 2011, Driver Inattention Monitoring System for Intelligent Vehicles: A Review, *IEEE Transactions on Intelligent Transportation Systems*, vol. 12, no. 2.
- [5] R. Foot et al., 2008, Questions raised on the design of the « dead-man » device installed on trams, *Cognition, Technology and Work*, Volume 10, n°1, pp.41-51.
- [6] V. Gadeppally et al., 2011, Driver/Vehicle State Estimation and Detection, 14th International IEEE Conference on Intelligent Transportation Systems, Washington.
- [7] K. Igarashi et al., 2004, Biometric Identification Using Driving Behavioral Signals, *IEEE International Conference on Multimedia and Expo*.
- [8] J. Krajewski et al., 2009, Steering wheel behavior based estimation of fatigue, *Proceedings of the 5th International Driving Symposium on Human Factors in Driver Assessment, Training and Vehicle Design*, USA.
- [9] A. Kurt et al., 2010, Hybrid-State Driver/Vehicle Modelling, Estimation and Prediction, 13th IEEE International Annual Conference on Intelligent Transportation Systems, Portugal.
- [10] G.S. Larue et al., 2009, A model to predict hypovigilance during a monotonous task, *Proceedings of the Australasian Road Safety Research, Policing and Education Conference*.
- [11] Y. Liang et al., 2007, Real-Time Detection of Driver Cognitive Distraction Using Support Vector Machines, *IEEE Transactions On Intelligent Transportation Systems*, Vol. 8, No. 2.
- [12] P. Naïm et al., 2004, *Réseaux Bayésiens*, Eyrolles.
- [13] I. Oppenheim et al., 2010, Critical state of the art and unified models of driver behavior, Work package n.1, ITERATE European Project.
- [14] J. Qiang et al., 2006, A probabilistic framework for modeling and real-time monitoring human fatigue, *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans*.
- [15] J. Qiang et al., 2002, Real-Time Eye, Gaze, and Face Pose Tracking for Monitoring Driver Vigilance, *Real-Time Imaging*, Volume 8, Issue 5, pp. 357–377.
- [16] L.R. Rabiner, 1989, A tutorial on hidden Markov models and selected applications in speech recognition, *proceedings of the IEEE*, vol.77, NO.2.
- [17] P. Richard et al., 2010, Vers le concept de stabilité humaine pour l'amélioration de la sécurité des transports, *Lambda Mu*, 17^{ème} Congrès de Maîtrise des Risques et de Sûreté de Fonctionnement, France.
- [18] G. Rigoll et al., 1996, A Comparison between Continuous and Discrete Density Hidden Markov Models for Cursive Handwriting Recognition, *Proceedings of the 13th IEEE Conference on Pattern Recognition*.
- [19] F. Vanderhaegen et al., 2011, A Benefit/Cost/Deficit (BCD) model for learning from human errors, *Reliability Engineering & System Safety*, volume 96, issue 7, pp. 757-766.
- [20] W. B. Verwey et al., 2000, Predicting drowsiness accidents from personal attributes, eye blinks and ongoing driving behavior, *Elsevier, Personality and Individual Differences*, Volume 28, Issue 1, pp 123–142.