



HAL
open science

APPLICATION DU DEEPLARNING DANS UNE ARCHITECTURE HUMS POUR LA CLASSIFICATION DU PROFIL D'EMPLOI DES SYSTEMES

Nicolas Rémy, Gabrielle Rives

► **To cite this version:**

Nicolas Rémy, Gabrielle Rives. APPLICATION DU DEEPLARNING DANS UNE ARCHITECTURE HUMS POUR LA CLASSIFICATION DU PROFIL D'EMPLOI DES SYSTEMES. Congrès Lambda Mu 21 “ Maîtrise des risques et transformation numérique : opportunités et menaces ”, Oct 2018, Reims, France. hal-02074493

HAL Id: hal-02074493

<https://hal.science/hal-02074493>

Submitted on 20 Mar 2019

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

APPLICATION DU DEEPLARNING DANS UNE ARCHITECTURE HUMS POUR LA CLASSIFICATION DU PROFIL D'EMPLOI DES SYSTEMES

DEEPLARNING IN HUMS ARCHITECTURE FOR USAGE PROFILE CLASSIFICATION

Nicolas Rémy, Gabrielle Rives

LGM

13, Av Morane Saulnier
78140 Vélizy-Villacoublay

Résumé

L'objectif de cette communication est de présenter les travaux réalisés par **LGM** dans le cadre des HUMS (Health and Usage Monitoring Systems) pour la classification automatique des profils d'emploi des systèmes, qui semble être une voie prometteuse pour l'amélioration de la disponibilité opérationnelle.

La communication décrit notamment l'architecture mise en place et les technologies utilisées, puis aborde les retours d'expériences liés à la mise en œuvre du projet INNOV'UP Proto 2017, supporté par la **Région Ile de France** et le pôle de compétitivité **CAP-DIGITAL**. L'objectif de ce projet était l'application des Réseaux Neuronaux aux données vibratoires, à des fins d'analyse de qualité de service dans des transports publics, et plus généralement à la classification des conditions d'exploitation de véhicules.

Summary

It is widely considered that HUMS (Health and Usage Monitoring Systems) shall deeply increase the knowledge of systems usage, directly leading to maintenance and support optimization, as well as availability improvement.

This article describes LGM's approach in HUMS design and architecture achieved in the context of an R&D project "Innov'Up Proto 2017" supported by French Paris Région and CAP-DIGITAL organization. The purpose of that project was to implement a proof of concept to apply DeepLearning technology for vibrations classification, for instance to estimate the service quality in public transportation, and more generally to analyze usage profile and exploitation for vehicles.

1 Introduction

Les HUMS sont basés sur des capteurs (IOT) instrumentant un système industriel, un équipement, un véhicule ou un aéronef, afin d'obtenir des données détaillées sur les conditions d'utilisation réelles en vue de l'optimisation de son exploitation. Une des premières applications modernes furent les systèmes ACARS dans l'aviation civile à partir des années 80, et dont l'exploitation s'est rendue particulièrement intéressante pour l'analyse des causes d'accident et de défaillance.

Dans le domaine de la maintenance, l'objectif est ainsi la mise en place de maintenances prévisionnelles permettant d'anticiper la réparation des équipements avant la survenue des pannes; notamment par l'analyse de signaux faibles précurseurs, couplée à la connaissance détaillée de l'historique d'exploitation. (Michel *et al.*, 2013)

Les HUMS, portés notamment par le développement de capteurs à bas coût (IOT) et le développement des réseaux informatiques, se propagent dans de très nombreux domaines industriels.

Ces capteurs permettent de récolter de grandes quantités d'informations (température, vibrations, champ magnétique, accélérations, ...), qu'il est nécessaire de mettre en perspective et donc de trier, catégoriser et exploiter.

De par les progrès qu'ils apportent, les nouveaux systèmes intègrent dès leurs conceptions des HUMS dédiés natifs.

Dans ce contexte, **LGM** développe une plateforme de HUMS générique (**MOKA** « Maintenance Oriented by Knowledge & Analytics »), afin de proposer une architecture modulaire, totalement autonome et indépendante du système analysé.

Cette solution permet ainsi la mise en place rapide d'instrumentation de systèmes existants, sans intervention significative sur le système opérationnel.

Cette approche permet aussi, pour un futur système, de prototyper l'architecture en termes de capteurs et données, et d'en analyser la plus-value, la faisabilité technique et l'intérêt opérationnel final, avant la mise en place à grande échelle de HUMS natifs.

2 Problématique

L'architecture générale des HUMS suit la représentation décrite dans l'ISO-13374. « Surveillance et diagnostic d'état des machines », avec l'ensemble des couches de traitement suivant :



Figure 1. Couches de traitement dans l'ISO-13374

Dans le cas de figure que nous souhaitons adresser ici, les capteurs utilisés sont des accéléromètres de conception analogues aux composants intégrés dans les téléphones mobiles, mais de qualité et performance supérieure, intégrés et durcis, autonomes en alimentation et communication.



Figure 2. Capteurs IOT Plug&Play MOKA

Ce type de capteurs est en effet très répandu, et potentiellement fournisseurs d'une quantité importante de données suivant la fréquence d'échantillonnage retenue.

Les principaux prétraitements appliqués à ces données sont des opérations relatives au dé-biaisage, et à la transformation dans le référentiel 3D attendu. Une fois cette phase de normalisation effectuée, différents algorithmes et analyses statistiques peuvent être intégrés.

La problématique de classification du profil de vie des systèmes que l'on souhaite adresser ici, se place donc au niveau des couches dites de « Data Manipulation/State Detection » de l'ISO-13374.

Dans le cadre particulier d'un véhicule, instrumenté à l'aide de capteurs accéléromètres/gyroscopes, il est intéressant de pouvoir identifier des événements pertinents ou des situations particulières, de façon à pouvoir apporter des indicateurs utiles à l'estimation du potentiel de certains équipements ou directement aux opérations de maintenance nécessaires.

Ces analyses sont assez similaires aux analyses destinées à évaluer le style de conduite des conducteurs (Meiring *et al.* 2015) mais avec une finalité différente.

De façon non-exhaustive on peut citer les événements et situations suivantes, susceptibles d'être détectées en

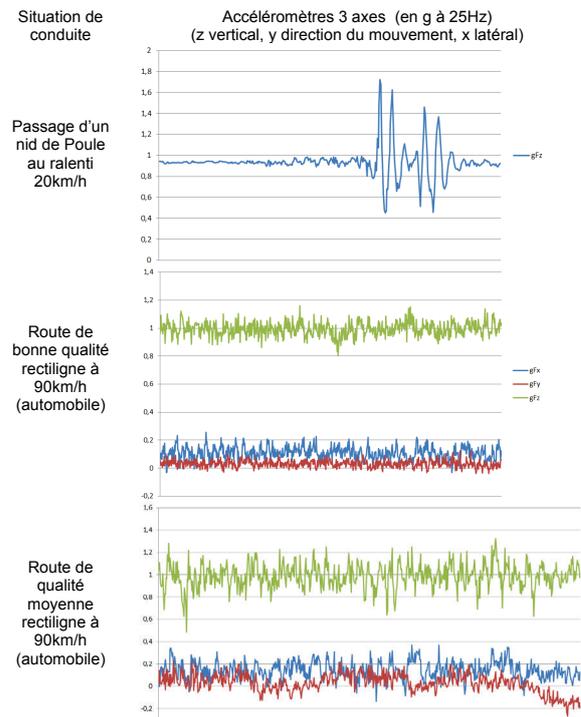
l'absence de toute information complémentaire (GPS, motorisation ou bus interne):

- Classification de la qualité de la route et de son revêtement,
- Chocs verticaux : passage de dos d'âne, nid de poules,
- Chocs frontaux, latéraux ou arrières,
- Accélération et freinages brusques ou marqués,
- Virages serrés ou marqués, inclinaison du véhicule,
- Tangage, roulis, pompage.
- Rythme des changements de vitesse.
- Changement de file, passage de rondpoint, parking ...

Même si cet aspect n'est pas abordé dans cette étude, on notera qu'un HUMS est aussi susceptible d'apporter des informations sur un véhicule à l'arrêt (chocs, transport), qui peuvent aussi se révéler intéressantes.

Néanmoins il faut aussi rappeler que les données issues de ces capteurs (accéléromètres/gyroscopes) sont extrêmement bruitées et donc d'exploitation délicate. C'est la raison principale des difficultés des implémentations de géolocalisation « indoor », car l'intégration de la vitesse puis de la position à partir des accélérations génère des erreurs cumulées trop importantes, entraînant une dérive de la position, sans recalage régulier par d'autres sources d'information (Wifi, GPS, ...).

Afin d'avoir une vision des signaux concernés, on présente ici quelques exemples de situations de conduites et de leurs représentations.¹



¹ Nota : Au premier abord, il peut sembler étonnant que les accéléromètres mesurent la gravité subie en tant qu'« accélération » (1g sur z), même lorsque le capteur est immobile. De fait les accéléromètres peuvent être schématisés comme des masses au bout d'un ressort dont on mesure la force exercée et dont on déduit l'accélération. La gravité est donc toujours présente, ce qui offre l'avantage pratique de pouvoir facilement identifier l'inclinaison du capteur, au repos.

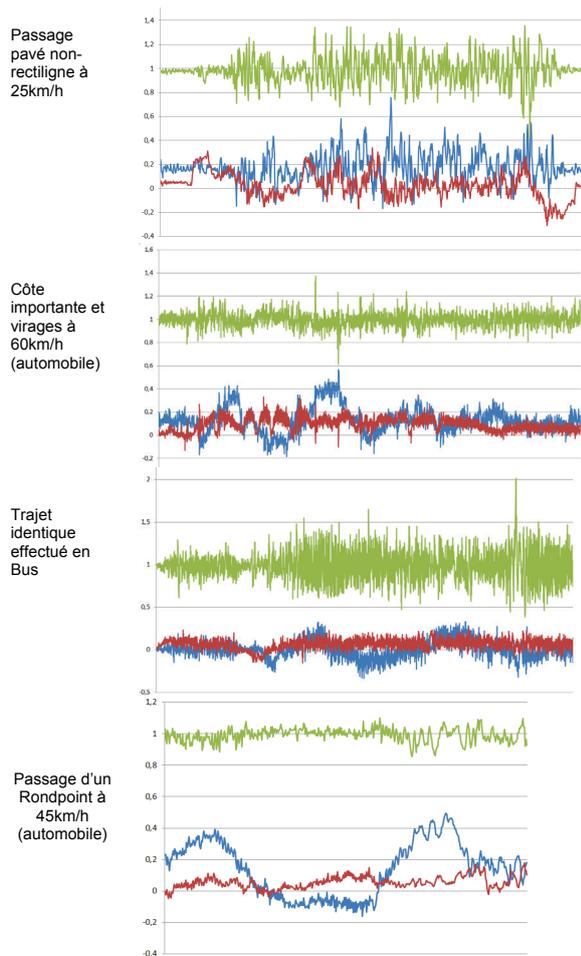


Figure 3. Signaux d'accéléromètres sur des situations de conduite

Sans surprise, on dénote une très grande influence du type de véhicule, de sa vitesse et de la qualité du revêtement, sur les vibrations enregistrées.

De fait, les vibrations ressenties dépendent de multiples facteurs : le profil de la route, la rugosité du revêtement, la chaîne d'amortissement du véhicule et la vitesse. Un standard international l'IRI (Indice de Rugosité International) définit une classification de la qualité des routes et son effet sur le confort des passagers.

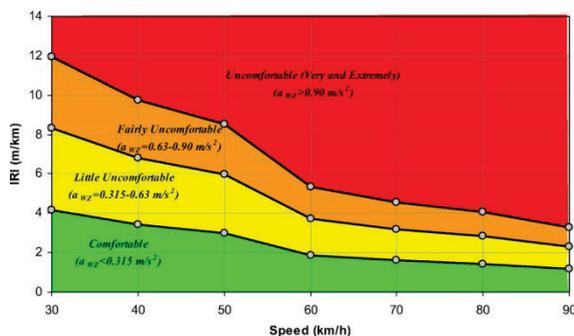


Figure 4. Evaluation du confort passager (Cantisani *et al.*, 2010)

Dans la suite de notre étude, nous nous sommes limités à une classification du type de revêtement à 3 niveaux. (Route, Chemin/Pavée, Terrain), qui pourront aussi être interprétés comme un indicateur de confort passager suivant la vitesse du véhicule.

3 Architecture du HUMS MOKA

On présente ici l'architecture du HUMS MOKA mise en place dans le cadre de ce projet ; et en particulier les algorithmes de Réseaux Neuronaux (RN) utilisés pour la classification supervisée du profil de vie.

3.1 Classification par Réseaux Neuronaux

L'utilisation des Réseaux Neuronaux (ou Deep Learning) pour l'implémentation d'algorithmes de classification en lieu et place d'algorithmes classiques (traitement du signal, approche statistique) a donné lieu à une multitude de projets d'Intelligence Artificielle ces dernières années. Les succès, notamment en reconnaissance d'images ou vidéos à base de réseaux à type CNN (Convolutional Neural Networks), font espérer leur généralisation à des applications multiples.

Par comparaison avec les algorithmes classiques de traitement du signal sans apprentissage qui nécessitent une forte modélisation du système analysée, et donc une compréhension approfondie du système suivi d'une phase de programmation importante, les Réseaux Neuronaux semblent pouvoir apporter des solutions génériques applicables à de nombreux contextes, à partir du moment où l'on dispose d'un jeu de données large, représentatif et répertorié. Ils constituent ainsi une nouvelle classe d'algorithmes de classification utilisables de façon industrielle, au même titre que les approches statistiques, mais potentiellement avec des délais de déploiement rapides, de par leurs généralités et leurs performances.

Dans le contexte spécifique de l'utilisation du HUMS MOKA décrit précédemment, les points négatifs des Réseaux Neuronaux que constituent l'absence de transparence de l'algorithme, l'effet Boite Noire, ou les temps d'apprentissage conséquents, ne sont pas impactant, à contrario d'utilisations dans d'autres contextes applicatifs.

Cependant, si une approche par modélisation est capable de prendre en compte des événements rares mais prévisibles, les Réseaux Neuronaux sont très dépendants du jeu de données utilisé, et donc de la représentativité des différents cas de figure. On peut donc considérer que l'utilisation des RN pour la classification supervisée du profil d'emploi d'un système semble bien adaptée, car les situations cibles sont suffisamment identifiées et catégorisées pour permettre un apprentissage exhaustif.

En parallèle, depuis la généralisation des téléphones mobiles munis d'accéléromètres et de gyroscopes, de très nombreux projets de R&D ont été mis en œuvre afin d'effectuer une classification automatique des activités des utilisateurs (Ming Zeng *et al.*, 2014). Sur le même thème, des montres connectées cherchent à identifier automatiquement le sport pratiqué par l'utilisateur. Cependant ces projets, malgré des résultats techniques encourageants, n'ont pas débouché sur des déploiements commerciaux ou industriels car les classifications recherchées sont trop nombreuses et complexes, et d'autre part, les vibrations parasites liées au port d'un mobile et à sa manipulation par l'utilisateur sont trop fréquentes, pour, en l'absence de données complémentaires, permettre l'identification de ces activités.

Ce type d'application grand public constitue probablement une limite haute de l'approche des Réseaux Neuronaux à

la classification des données d'accéléromètres/gyroscopes isolément.

Cependant, dans le contexte des HUMS dont les capteurs sont implantés à des endroits déterminés du système cible, puis calibrés insitu, les effets parasites sont fortement réduits par rapport aux cas d'application précédents.

Tous ces éléments issus de projets de R&D préalables, consolidés par le déploiement de toolkits logicielles de DeepLearning matures, en l'occurrence MATLAB® de MathWorks, ont justifiés notre approche par les RN pour ce prototype.

3.2 L'implémentation par RN de type LSTM

De nombreuses architectures de RN pour la classification supervisée ont été développées en IA, dont on peut isoler deux grandes catégories. Les CNN (Convolutional Neural Networks) qui effectuent une classification par un traitement feed-forward à partir des données d'entrée au travers de différentes couches de neurones, et les RNN (Recurrent Neural Network) qui en complément de l'approche feed-forward, conservent une mémorisation des états précédents par rebouclage des sorties, afin d'utiliser cet historique pour les classifications ultérieures.

S'il est possible malgré tout d'imaginer utiliser les CNN pour une classification d'information temporelle, en définissant une fenêtre fixe d'analyse en donnée d'entrée, les RNN sont particulièrement adaptés à ces problématiques de reconnaissance de séquences et de séries temporelles.

Parmi les RNN, les réseaux dits LSTM (Long short-term memory) sont une solution mature, utilisée dans de nombreuses applications telles que la reconnaissance de la parole ou l'analyse audio/video,... (Klaus Greff *et al.*, 2017)

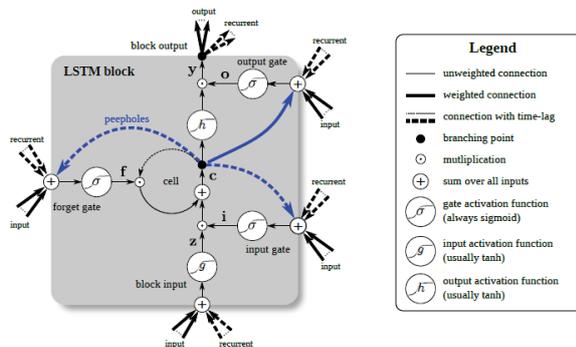


Figure 5. Composant d'un LSTM (arXiv LSTM: A Search Space Odyssey)

L'architecture de classification du HUMS MOKA est donc une succession de RN de type LSTM, dédiés à des classifications d'états exclusifs. Il serait en effet inenvisageable de construire un réseau unique global produisant une classification de l'ensemble des états, en une seule étape, que ce soit pour des problèmes de performance de l'apprentissage que d'évolutivité ou de modularité logicielle.

Même s'il est possible d'utiliser des architectures plus complexes (DeepSense : Shuochao Yao *et al.*, 2017) mixant différents types de RN, notre conception s'est

limitée à l'utilisation d'une hiérarchie de type LSTM, couplée avec les prétraitements et post-traitements nécessaires.

Parmi les prétraitements on notera la nécessité de synchroniser l'ensemble des données d'entrée selon une fréquence définie, les Réseaux LSTM fonctionnant par défaut sur des séquences avec un intervalle de temps fixe. Cette contrainte entraîne la nécessité d'estimer par interpolation les données dans le cas d'entrées ayant des fréquences de rafraichissement différentes ou variables, ou dans le cas d'acquisition de données aberrantes détectées puis supprimées.

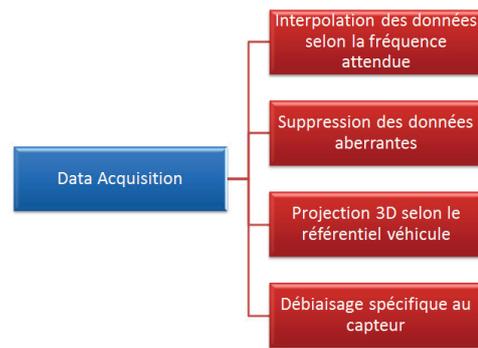


Figure 6. Traitements de la couche d'acquisition

Une fois ces prétraitements mis en œuvre, et le calcul de la vitesse de véhicule réalisée (intégration des accélérations et recalage régulier sur l'identification de l'arrêt), il est possible d'effectuer la classification exclusive via trois RN de type LSTM.

Les différents RN utilisés sont composés d'une à deux couches d'environ une centaine de neurones.

Le premier RN relatif au type de route sert ensuite à orienter sur les deux RN complémentaires (chocs ponctuels et catégorie du mouvement), dont l'apprentissage est spécifique à chaque type de route. Les événements ponctuels sont caractérisés et comptabilisés par essieux.

Chaque RN est configuré pour tenir compte d'une durée d'historique spécifique (resp. ~10, 5 et 2.5 secondes) selon la nature des événements à identifier. Les données sont émises par les capteurs avec une fréquence allant de 10 à 25Hz suivant les équipements et paramètres effectués.



Figure 7. Traitements de la couche de manipulation (Classification)

A partir de ces données il est ensuite possible de produire des indicateurs de fonctionnement « classiques » pour l'analyse du profil de vie, voire des indicateurs de confort passager.

4 Déploiement et expérimentation

Dans le cadre des projets INNOV'UP Proto 2017, et grâce au support de la **Région Ile de France** et du pôle de compétitivité **CAP-DIGITAL**, **LGM** a pu mettre en œuvre cette implémentation des RN dans l'architecture HUMS **MOKA**, et la tester dans le contexte de l'analyse de la qualité de Service des transports publics.

L'objectif était clairement la réalisation d'un prototype et non d'un produit commercialisable ou diffusable, et fut présenté aux salons FUTUR.E.S.IN PARIS et EuroSatory en Juin 2018.



Présentation du démonstrateur **MOKA** lors des salons EuroSatory et Futur en Seine 2018



Figure 8. Démonstrateur HUMS **MOKA**

Bien que des expérimentations aient eu lieu dans différents moyens de transport, aucune relation ou communication avec les exploitants n'étaient nécessaires ou souhaitées.

4.1 Acquisition des données

La phase d'acquisition des données est un point très important dans le cadre des applications de classification par les RN.

Contrairement à des applications d'IA purement digitales (reconnaissance d'image, vidéo, ...) où les jeux de données disponibles sont extrêmement vastes grâce à Internet, ce type d'application requiert une phase d'acquisition physique réelle.

Plusieurs phases d'expérimentations ont ainsi été effectuées afin de cumuler un jeu de données significatif, représentatif et exploitable.

En premier lieu des expérimentations lors de trajets réalisés en Bus en Région parisienne ont été faites par **LGM**, à l'aide d'une application mobile, servant à l'opérateur à classifier (ou labéliser) l'ensemble des événements ressentis.

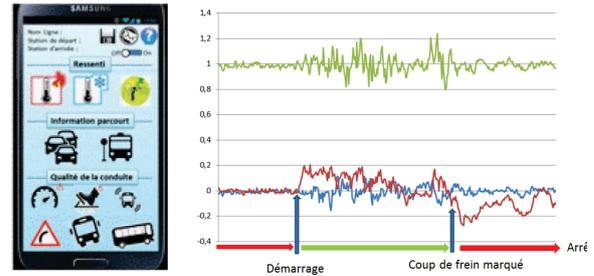


Figure 9. Phase d'expérimentation en Bus

Cependant ces jeux de données se sont révélés peu concluants et adaptés aux phases d'apprentissage pour de multiples raisons :

- Variabilité de l'évaluation des expérimentateurs,
- Variabilité de la position au sein du véhicule,
- Erreurs ou oublis de saisie,
- Décalage temporel entre l'événement et la saisie
- Evènements simultanés,
- Absence d'évènements pertinents (chocs, dos d'âne).

Au final ces données réelles nécessitaient trop de post-traitements manuels pour être exploitables facilement pour l'apprentissage.

Il aurait certainement été possible de mettre en place des protocoles d'acquisition plus longs et plus formels afin d'acquérir des jeux de données classifiés robustes, cependant l'objectif du projet n'étant pas de finaliser une application professionnelle commercialisable, mais d'expérimenter l'approche par RN, cette phase d'expérimentation à des fins d'acquisition fut arrêtée, au profit de deux approches complémentaires :

- Développement d'un banc permettant la production de scénarios parfaitement maîtrisés,
- Acquisition de données en véhicule particulier sur des trajets et scénarios contrôlés.

Le banc de simulation est constitué d'un trépied permettant des inclinaisons de l'ordre de +/- 20° avec une amplitude verticale de 4 cm, afin de produire les accélérations et vibrations nécessaires au niveau du capteur.



Figure 10. Banc de simulation avec le capteur **MOKA**

Evidemment le banc ne permet que de reproduire des amplitudes et vibrations limitées mais néanmoins compatibles avec les domaines de valeurs des évènements réels (+- 1,5g).

Il fut alimenté à partir de scénarios réels ou théoriques simplifiés et permettait de produire différents évènements parfaitement maîtrisés (chocs, virages, dos d'ânes, accélérations, freinage, tangage, roulis), couplés avec des

simulations vibratoires relatives aux types de routes, à une vitesse définie.

Type de route simulée	Accélération verticale max	Vitesse représentative
Route	+/- 0.2g	90 km/h
Chemin/ Route pavée	+/- 0.4g	60 km/h
Terrain	+/- 0.6g	30 km/h

Tableau 1. Simulation des vibrations liées à la qualité de la route

L'autre complément de données fut apporté par des jeux de tests réels dans des véhicules, mais parfaitement contrôlés, maîtrisés et reproductibles. Ces données servirent aussi à calibrer les scénarios du banc.

Les scénarios ont été réalisés avec des capteurs physiques distincts, selon des fréquences d'acquisition différentes, afin de disposer de jeux de données complémentaires et plus génériques, et de vérifier la robustesse de la classification.

Dans le cas d'utilisation du banc, la vitesse transmise aux RN était définie selon le scénario et non calculée à partir des capteurs, afin de ne pas essayer de reproduire les phases d'accélération initiales du véhicule sur celui-ci. Pour les données réelles, la vitesse était calculée avant transmission.

Au final plusieurs dizaines d'heures de fonctionnement classifiées ont pu être accumulées.

4.2 L'apprentissage et la classification supervisée

Les activités relatives à l'apprentissage des RN nécessitent la sélection des cas d'apprentissage et la séparation des données de validation, puis l'optimisation des différents paramètres des RN (architecture, paramétrage).

En particulier la sélection des cas d'apprentissage doit surévaluer les cas peu fréquents afin qu'ils soient identifiés correctement.

Sur les données recueillies la classification du type de route parcourue est bien effectuée avec des taux de reconnaissance >90% à partir de données réelles ou simulées.

type de route Confusion Matrix

Output Class	Chemin	Route	Terrain	
Chemin	64440 31.4%	8621 4.2%	499 0.2%	87.6% 12.4%
Route	2775 1.4%	59827 29.1%	31 0.0%	95.5% 4.5%
Terrain	1245 0.6%	4 0.0%	67955 33.1%	98.2% 1.8%
	94.1% 5.9%	87.4% 12.6%	99.2% 0.8%	93.6% 6.4%
	Chemin	Route	Terrain	

Target Class

Tableau 2. Classification du type de route

Dans le cas d'un bon revêtement (contexte Route), les chocs ponctuels (nids-de-poule, dos-d'âne), sont aussi correctement reconnus avec des taux de classification > 80%.

Confusion Matrix

Output Class	Route	Route-Dosdane	Route-Niddepoule	
Route	185 45.2%	3 0.7%	20 4.9%	88.9% 11.1%
Route-Dosdane	1 0.2%	111 27.1%	27 6.6%	79.9% 20.1%
Route-Niddepoule	3 0.7%	6 1.5%	53 13.0%	85.5% 14.5%
	97.9% 2.1%	92.5% 7.5%	53.0% 47.0%	85.3% 14.7%
	Route	Route-Dosdane	Route-Niddepoule	

Target Class

Tableau 3. Identification des Dos d'Ane/Nids de poule²
Les résultats sont donc globalement acceptables.

Il faut cependant noter que contrairement à des approches statiques plus classiques, il n'est pas possible d'améliorer spécifiquement une classification effectuée pour un RN

² Dans cet exemple il faut ainsi comprendre que globalement 85,3% des situations sont correctement classifiées par rapport à la répartition des situations proposées, mais de façon peu homogène. Ainsi la classification des « dos-d'âne » est exacte dans 79,9% des cas (20,1% de faux positifs), mais 7,5% des cas réels de « dos-d'âne » sont mal interprétés (faux négatifs). A contrario les Nids-de-poule sont faiblement identifiés (53%) mais avec peu de faux positifs (14,5%) (classification restrictive).

donné, autrement que par la modification générale des paramètres du RN et du jeu de données utilisé.

Pour l'analyse de la dynamique des mouvements dans un contexte de « Route », les résultats sont de même ordre, autour des 80%.

Output Class	Route	Route-Acceleration	Route-Freinage	Route-Virage-D	Route-Virage-G	
Route	3479 20.9%	37 0.2%	34 0.2%	39 0.2%	1 0.0%	96.9% 3.1%
Route-Acceleration	583 3.5%	2663 16.0%	13 0.1%	0 0.0%	0 0.0%	81.7% 18.3%
Route-Freinage	598 3.6%	15 0.1%	2538 15.3%	135 0.8%	0 0.0%	77.2% 22.8%
Route-Virage-D	560 3.4%	0 0.0%	82 0.5%	2219 13.3%	0 0.0%	77.6% 22.4%
Route-Virage-G	663 4.0%	0 0.0%	0 0.0%	286 1.7%	2684 16.1%	73.9% 26.1%
	59.1% 40.9%	98.1% 1.9%	95.2% 4.8%	82.8% 17.2%	100.0% 0.0%	81.7% 18.3%
	Route	Route-Acceleration	Route-Freinage	Route-Virage-D	Route-Virage-G	
	Target Class					

Tableau 4. Classification de la dynamique du mouvement sur un bon revêtement.

De façon logique les chocs (nids de poules, dos d'âne) ne sont plus détectés correctement lorsque le revêtement se dégrade (catégories Chemin/Terrain), noyés dans le bruit ambiant.

Dans ces résultats, la classification est basée sur la meilleure reconnaissance obtenue parmi les différents labels, mais il serait possible d'utiliser les probabilités de reconnaissance afin d'améliorer la confiance dans les résultats, en fixant un seuil à partir duquel la classification serait considérée comme valide et exploitable.

Dans ce cas on augmenterait la qualité de reconnaissance des événements au détriment de la non-classification d'un certain nombre de situations non-discriminées.

Le choix entre ces deux approches dépendra de la nature de l'application et de la sensibilité de la reconnaissance.

On notera que cette probabilité de reconnaissance pourrait à l'inverse être un indicateur d'une situation anormale, non classifiable parmi les événements standards, qui pourrait être une alerte pour la maintenance. Cette approche n'a cependant pas été explorée dans cette expérimentation.

5 Conclusions, Perspectives et Limites

Ce paragraphe fait un premier bilan de cette approche, selon différents aspects techniques.

5.1 Comparaison avec une approche classique

LGM avait déjà développé un composant électronique d'évaluation de la qualité de conduite dans les bus de la région Toulousaine pour le compte de TISSEO (en 2004), mais avec des technologies électroniques et logicielles classiques, dont l'objectif était principalement de détecter des franchissements de seuils sur les accélérations.

On définissait dans ce contexte un seuil de confort fixé par deux critères :

- Un seuil d'accélération résultante subie par le passager pendant une durée minimale.
- Un seuil de secousse, de faible intensité et de courte durée, mais génératrice d'inconfort certain pour le passager.

Ces calculs nécessitaient la mise au point de pondérations et de niveaux de seuils ad-hoc. Cependant, par rapport à la simplicité de la problématique, l'apport des RN pour produire ces indicateurs serait très faible, et de surcroît perdrait leur caractère explicatif qui peut être nécessaire dans ce type d'application.

Le positionnement des RN doit plutôt être concentré sur la capacité à reconnaître une signature globale dans le signal analysé, notamment multi-capteurs, (mouvements, chocs, ..) afin d'effectuer une analyse complexe du signal plutôt que sur la production d'un indicateur direct.

Compte tenu des difficultés techniques non négligeables liées à l'implémentation des RN (large jeux de données représentatif nécessaire, apprentissage global), il semble raisonnable de n'utiliser ces technologies que dans les cas où les approches classiques n'offrent pas de bonnes performances ou lorsque le coût de modélisation liée à une approche classique serait trop élevé.

Les RN peuvent néanmoins constituer une alternative intéressante lorsque des performances de classification de l'ordre de 90% sont acceptables. Bien évidemment ce résultat pourrait être automatiquement amélioré par la mise en parallèle de différents algorithmes (y compris d'autres RN configurés différemment), moyennant la multiplication des implémentations.

Au final, notre premier retour d'expérience sur les RN dans la classification des profils d'emploi, semblent nous indiquer qu'ils sont applicables dans les cas où :

- Les jeux de données sont importants, et représentatifs, (pb des événements rares),
- Les performances de classification attendues ne sont pas trop sévères (~90% en environnement réel)
- Le caractère explicatif de la classification n'est pas nécessaire.
- La modélisation par des algorithmes classiques serait trop coûteuse, notamment dans le cas de systèmes complexes et de données multi-capteurs (signaux de nature différentes).

5.2 Implémentation potentielle des RN au sein des capteurs

Par défaut la classification du profil de vie est effectuée de façon asynchrone par l'environnement BackOffice du HUMS puis interprétée par la chaîne des traitements statistiques. Il peut ainsi sembler inutile de vouloir effectuer cette classification en temps réel dès la phase d'acquisition des données par les capteurs eux-mêmes. Cependant, même si cette solution reste valable pour une application de pure maintenance, une classification au plus tôt, dès l'acquisition des données possède certains avantages pratiques, par la :

- Réduction du flux de données et de la communication réseau,
- Réduction du stockage intermédiaire des données,
- Minimisation de la consommation électrique des capteurs (à relativiser entre l'utilisation CPU vs communication réseau),
- Adaptation dynamique des seuils ou fréquences des informations à tracer selon l'état.

D'autre part, indépendamment de la complexité technique de l'implémentation, les algorithmes de RN sont peu gourmands en CPU lors de la phase d'exécution, à contrario avec la phase d'apprentissage.

C'est dans cette optique d'optimisation que nous étudions le déploiement de ces algorithmes directement au sein des capteurs, configurés avec le paramétrage d'apprentissage applicable, ce qui impose d'effectuer de façon complémentaire l'implémentation de l'ensemble des prétraitements du RN. Il va de soi que cette approche est antagoniste avec les phases d'apprentissage, qui nécessitent l'acquisition de l'ensemble des données brutes et leur centralisation au niveau du référentiel du HUMS.

5.3 Intégration de capteurs multiples

Pour cette première étude, les données traitées étaient exclusivement les accélérations issues d'un seul capteur sur le véhicule. Il est clair que l'exploitation des données des gyroscopes serait intéressante pour l'analyse de la dynamique du mouvement, et que d'autre part, le positionnement de plusieurs capteurs permettrait d'obtenir des informations plus complètes (différentiel des capteurs) sur la dynamique du véhicule.

Enfin, l'intégration au sein des RN de signaux de nature différente (température, bruit ambiant, ..) pourrait aussi constituer une piste intéressante, par la capacité potentielle des RN à fusionner des données hétérogènes.

5.4 Conclusions

Il est clair que l'expérimentation réalisée dans le cadre de ce projet n'a permis d'adresser que des cas assez simplifiés de classification du profil de vie d'un véhicule, mais a cependant permis de cerner les possibilités et les limites du DeepLearning dans le cadre de ce type d'application.

L'objectif est dorénavant de pouvoir consolider cette analyse dans le domaine spécifique des véhicules, mais aussi de généraliser cette approche à de nouveaux domaines, ferroviaire ou naval, et de nouveaux systèmes où les besoins de classification automatique du profil de vie sont pertinents.

6 Remerciements

Nous remercions toute l'équipe de **LGM** ayant participé à l'implémentation et au déploiement de ce projet particulièrement passionnant et notamment F.Delle, C.Pillet, L.Bellabiod, M.Monnot et D.Cuoq, ainsi que les équipes de **CAP-DIGITAL** et de la **Région Ile de France**, et en particulier L.Pommereau, pour son soutien et support pour ce projet et l'organisation des présentations au salon FUTUR.E.S.IN PARIS 2018.

7 Références bibliographiques

Stéphane Michel. 2013. Apport des HUMS au maintien en condition opérationnelle des systèmes complexes. QUALITA2013.hal-00823146

Meiring, G.A.M.; Myburgh, H.C. A Review of Intelligent Driving Style Analysis Systems and Related Artificial Intelligence Algorithms. Sensors, 2015 15, 30653-30682

Ming Zeng, Le T. Nguyen, Bo Yu, Ole J. Mengshoel, Jiang Zhu, Pang Wu, Joy Zhang. Carnegie Mellon University. Convolutional Neural Networks for Human Activity. 2014 ICST. 978-1-63190-024-2

Shuochao Yao, Shaohan Hu, Yiran Zhao, Aston Zhang, Tarek Abdelzaher DeepSense: A Unified Deep Learning Framework for Time-Series Mobile Sensing Data Processing, 2017, arXiv:1611.01942

Klaus Greff, Rupesh K. Srivastava, Jan Koutn'ik, Bas R. Steunebrink, Jürgen Schmidhuber : LSTM: A Search Space Odyssey 2017, arXiv:1503.04069v2

Giuseppe Cantisani, Giuseppe Loprencipe Sapienza, Università di Roma, Rome, Italy: Road Roughness and Whole Body Vibration: Evaluation Tools and Comfort Limits. Journal of Transportation EngineeringSeptember 2010 Volume 136, Issue 9 (818 - 826)