

Analyse statistique robuste et apprentissage profond à partir de séquences spectrales d'EEG pour la détection de somnolence

Antonio Quintero-Rincón*, Hadj Batatia**

*Departament of Electronic, Catholic University of Argentina (UCA), Buenos Aires, Argentina
antonioquintero@uca.edu.ar,
<http://uca.edu.ar>

**Heriot-Watt University, MACS School, Knowledge park, Dubai-Campus
h.batatia@hw.ac.uk
<https://researchportal.hw.ac.uk/en/persons/hadj-batatia>

Résumé. La somnolence des conducteurs est une cause majeure d'accidents de la route. L'électroencéphalogramme (EEG) est considéré comme le prédicteur le plus robuste de somnolence. Cet article propose une méthode nouvelle, simple et rapide pour détecter la somnolence de conducteurs, qui peut être implémentée en temps réel en utilisant une seule électrode. L'étude vise deux objectifs. Le premier consiste à déterminer le canal EEG unique le plus pertinent pour surveiller la somnolence. Cela est fait en procédant par analyse de covariance maximale. Le second objectif consiste à développer une méthode d'apprentissage profond à partir de ce canal. Pour cela, des caractéristiques spectrales du signal sont d'abord extraites. Un modèle de réseau récurrent à mémoire court et long terme (LSTM) est alors utilisé pour détecter les états de somnolence. Des expériences ont été conduites avec 12 signaux EEG pour discriminer les états de somnolence et d'alerte. Notre résultat principal est que le canal le plus significatif est TP7 situé dans la région temporo-pariétale gauche. Cela correspond à une zone partagée entre la conscience spatiale et la navigation spatiale visuelle. Ce canal est aussi relié à la faculté de prudence. En plus, malgré le petit nombre de données, la méthode proposée permet de prédire la somnolence avec une précision de 75% et un délai de 1.4 secondes. Ces résultats prometteurs mettent en lumière des données intéressantes à considérer pour la surveillance de la somnolence.

Mots-clés : analyse robuste, biLSTM, somnolence, EEG.

1 Introduction

L'électroencéphalogramme (EEG) est l'enregistrement de l'activité électrique du cerveau, détectée par des électrodes placées sur le cuir chevelu. Les variations des ondes cérébrales captées par l'EEG sont corrélées aux conditions neurologiques, aux états physiologiques et au

Détection de somnolence par analyse de EEG et apprentissage profond

niveau de conscience. La somnolence des conducteurs est une cause majeure des accidents de la route, liée à 20% des cas (BalasuBramanian et Bhardwaj, 2018). Ces accidents causent plus de mortalité et morbidité que d'autres types d'accidents à cause de la grande vitesse au moment de l'impact (Horne et Reyner, 1995). Pour prévenir ces accidents, la détection de somnolence en temps réel chez les conducteurs est un besoin crucial. Cela permettrait le développement d'appareils d'alerte efficaces. Selon Lal et Craig (Lal et Craig, 2002), l'EEG peut être l'un des prédicteurs les plus efficaces de la somnolence. Par conséquent, un grand nombre de travaux de recherche ont étudié des méthodes de détection par analyse de signaux EEG.

Dans (Lal et Craig, 2002), les signaux EEG ont été analysés dans différents rythmes cérébraux et les résultats rapportés indiquent que les ondes delta (δ) et theta (θ) augmentent respectivement de 22% et 26% durant la transition vers l'état de somnolence. Ils indiquent aussi que l'activité des ondes alpha (α) et beta (β) n'augmente que de 9% et 5% respectivement. Partant de ces résultats, Lal et Craig (Lal et al., 2003) ont développé un algorithme robuste de détection de somnolence qui classe les bandes de fréquences en 4 phases : alerte, transition vers la somnolence, transition-posttransition, et posttransition.

Jap et al. (Jap et al., 2009) ont évalué ses quatre phases pendant la conduite monotone. Ils ont montré une augmentation du rapport onde-lente sur onde-rapide dans les activités EEG, avec $(\theta + \alpha)/\beta$ donnant l'augmentation la plus large. Wei et al. (Wei et al., 2012) ont transformé les données EEG en bandes (θ , α et β) et ils ont évalué 11 paramètres d'énergie pour déterminer l'indicateur optimal de somnolence. Ils ont sélectionné FP1 et O1 comme les électrodes significatives en utilisant une analyse en composantes principales à noyau (kACP). Ils rapportent une précision de 92%. Simon et al. (Simon et al., 2011) ont étudié les alpha spindles. Il s'agit de rafales courtes (0.5 – 2.0 s) d'activité alpha de haute fréquence (Lawhern et al., 2013). Les résultats rapportés indiquent que les paramètres de rafales alpha aboutissent à une augmentation de la sensibilité et la spécificité de détection de la somnolence.

Les méthodes d'entropie ont été étudiées par plusieurs auteurs pour détecter la somnolence à partir de signaux EEG. Hu (Hu, 2017) ont extrait des paramètres de quatre mesures d'entropie (entropie spectrale, entropie approximative, entropie d'échantillon, entropie floue) à partir d'un seul canal EEG. Dix classifieurs ont été utilisés pour comparer ces paramètres. Le classifieur forêts d'arbres décisionnels a donné la performance optimale en utilisant l'entropie floue du canal FP4, avec une précision de 96.6%. Mu et al. (Mu et al., 2017) ont combiné les mêmes 4 entropies calculées de signaux EEG enregistrés dans des états d'alerte et de somnolence. Les résultats (précision de 98.57%) montrent que la combinaison d'entropies donne une meilleure performance que l'utilisation d'une seule entropie. L'évaluation des différentes électrodes a montré que T5, TP7, TP8 et FP1 donnent de meilleurs résultats. Min et al. (Min et al., 2017) ont proposé la fusion de plusieurs entropies d'EEG et ont rapporté une précision de détection de somnolence de 98.3%, avec une sensibilité de 98.3%, et une spécificité de 98.2%. Ils ont aussi conclu que les canaux T6, P3, TP7, O1, Oz, T4, T5, FCz, FC3 et CP3 sont significatifs.

Il existe de nombreuses autres méthodes dans la littérature pour détecter les états cérébraux de conducteurs à partir de signaux EEG. Une grande partie de ces méthodes se base sur l'apprentissage automatique avec des vecteurs de paramètres très variés. Un état de l'art complet sur les techniques d'apprentissage automatique pour l'analyse de comportements de conducteurs peut être trouvé dans (Elassad et al., 2020).

Le réseau à mémoire court et long terme (LSTM) est un type de réseaux de neurones récurrents (RNN) capable d'apprendre des dépendances de long-terme dans les séries temporelles

(Hochreiter et Schmidhuber, 1997). La variante LSTM bidirectionnel (BiLSTM) est très efficace sur des données de longueur fixe (Schuster et Paliwal, 1997). Ses deux couches cachées, connectées aux entrées et sorties, permettent la circulation de l'information dans les deux sens. Les biLSTM ont été étudiés pour le traitement d'EEG par plusieurs chercheurs (Li et Jung, 2020; Hou et al., 2020; Yang et al., 2020; Fares et al., 2019).

Les méthodes d'analyse statistique monovariée et multivariée permettent l'étude de corrélation dans les données. Le sous-ensemble de techniques d'analyse robuste concernent les méthodes résilientes aux données aberrantes et applicables aux distributions non normales. Les méthodes classiques de moyenne et de covariance s'appliquent en situation de non-normalité mais ne sont pas robustes (Olive et al., 2017). Les méthodes d'analyse robuste ont été appliquées de nombreuses fois aux signaux EEG (Molinari et Dumermuth, 1986; Yong et al., 2008; Sameni et Seraj, 2017; Uehara et al., 2017). Ces signaux sont néanmoins considérés comme ayant une distribution normale (Quintero-Rincón et al., 2018), ce qui permet l'application de méthodes de statistiques optimales (Maronna et al., 2019). En neurosciences, l'analyse multivariée est employée pour l'étude simultanée d'états et d'interactions entre plusieurs régions cérébrales, alors que les méthodes monovariées se concentrent sur une région unique (Quintero-Rincón et al., 2016).

La présente étude propose une nouvelle méthode simple et rapide pour détecter la somnolence chez les conducteurs à l'aide d'un seul canal EEG. Elle se compose de deux étapes. La première consiste à déterminer le canal le plus pertinent à l'aide d'une méthode robuste d'analyse en maximum de covariance. La seconde étape, développe un réseau biLSTM pour différencier les états d'alerte et de somnolence, en utilisant des paramètres spectraux du canal déterminé (Hochreiter et Schmidhuber, 1997; Schuster et Paliwal, 1997). Plus précisément, on transforme la série temporelle de données EEG en une séquence de paramètres pour alimenter le réseau BiLSTM. Dans ce travail, nous avons analysé la somnolence à l'aide d'un ensemble de données composé de signaux EEG de 32 canaux provenant de 12 patients, fourni par Jiangxi University of Technology (Min et al., 2017). L'analyse en maximum de covariance a donné le canal TP7, situé dans la région temporo-pariétale, comme étant le plus pertinent (Fig. 1). Cette région concerne *la conscience spatiale et la navigation spatiale visuelle* en relation directe avec la conduite, et donc très pertinente pour l'analyse de somnolence. Ce canal est aussi relié à la faculté de prudence. Le réseau BiLSTM développé permet de détecter les changements entre alerte et somnolence durant des périodes longues de conduite. Les techniques mises en œuvre dans cette étude sont tous bien connues. Cependant, à notre connaissance, elles n'ont jamais été utilisées pour traiter le problème de la somnolence. La suite de l'article est organisée comme suit. La section 2 décrit la méthode proposée en 4 étapes : description des données (section 2.1), sélection du canal pertinent (section 2.2), transformation spectrale des données (section 2.3), et création du modèle prédictif (section 2.4). Dans la section 3, nous analysons et discutons les résultats obtenus. Finalement, la section 4 esquisse des conclusions et des perspectives.

2 Processus de science de données

Un processus standard de science de données a été mis en œuvre pour cette étude (Fig.2). D'abord une phase de recherche et d'acquisition de données a été conduite. Puis, la seconde phase a consisté à prétraiter les données en deux étapes. D'abord, nous avons sélectionné l'électrode la plus pertinente pour l'analyse de somnolence. Ensuite, les données de ce canal ont été

Détection de somnolence par analyse de EGG et apprentissage profond

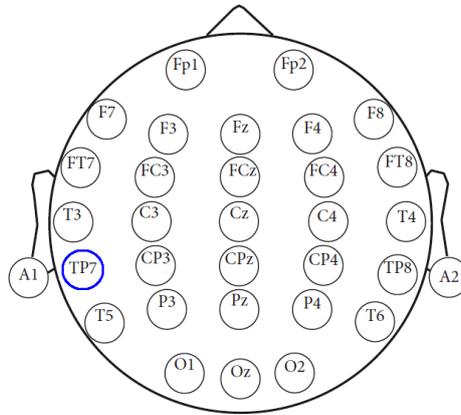


FIG. 1 – Position et nomenclature des électrodes avec les lobes sous-jacents, (T) lobe temporal, (P) lobe pariétal, (O) lobe occipital et (F) lobe frontal.

transformées en une séquence de paramètres spectraux. La troisième phase a consisté à apprendre un modèle prédictif pour détecter les états de somnolence. Ces phases sont présentées dans les sections suivantes.

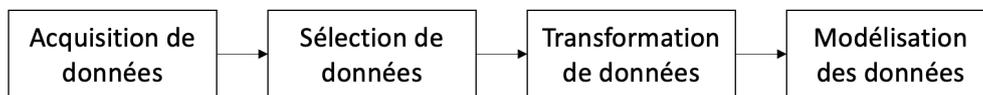


FIG. 2 – Etapes de notre méthode.

2.1 Description des données

Une base de données composée de 12 signaux unipolaires de somnolence et de 12 autres d'alerte a été fournie par Min et al. (2017). Les sujets concernés sont 12 étudiants âgés entre 19 et 24 ans. La tâche a consisté à conduire un véhicule statique à l'aide d'un simulateur de conduite dans un environnement contrôlé par logiciel. Pour chaque sujet, deux EEG ont été enregistrés : un correspondant à une conduite en état d'alerte, et le second à une conduite en état de somnolence. Les signaux correspondant à l'état d'alerte ont été enregistrés pendant une conduite de 15 minutes. Les signaux de conduite en état de somnolence ont été acquis quand les sujets ont montré des signes de fatigue selon l'échelle de Lee Lee et al. (1991) et l'échelle de Borg CR-10 Borg (1990), après une conduite entre 60 et 120 minutes. Les deux types de signaux consistent en 32 canaux de durée de 5 minutes, numérisés avec la fréquence $f_s = 1000$ Hz.

2.2 Sélection de l'électrode pertinente

Soit $\mathbf{X} \in \mathbb{R}^{M \times N}$ la matrice regroupant les M signaux EEG $\mathbf{x}_m \in \mathbb{R}^{1 \times N}$ mesurés simultanément par différents canaux en N instants temporels. En appliquant l'algorithme MCD (Minimum covariance determinant) (Rousseeuw et Driessen, 1999), nous estimons les paramètres $(\hat{\boldsymbol{\mu}}, \hat{\boldsymbol{\Sigma}})$ de la distribution uni-modale elliptique symétrique de nos données multivariées \mathbf{X} . Ces paramètres sont donnés par les expressions suivantes

$$\hat{\boldsymbol{\mu}} = \frac{\sum_{i=1} W(d_i^2) \mathbf{x}_i}{\sum_{i=1} W(d_i^2)} \quad (1)$$

$$\hat{\boldsymbol{\Sigma}} = c_0 \frac{1}{N} \sum_{i=1} W(d_i^2) (\mathbf{x}_i - \hat{\boldsymbol{\mu}})^* (\mathbf{x}_i - \hat{\boldsymbol{\mu}})^T \quad (2)$$

où $d_i = d(\mathbf{x}_i, \hat{\boldsymbol{\mu}}, \hat{\boldsymbol{\Sigma}})$ est la distance de Mahalanobis, $W(\cdot) = I(\cdot \leq \sqrt{\chi_{M,0.975}^2})$ est une fonction de poids avec $I(\cdot)$ l'indicatrice, $*$ est le complexe conjugué, $\boldsymbol{\mu}$ est la moyenne. Le paramètre c_0 appelé facteur de consistance est donné par $\alpha / F_{\chi_{M+2}^2}(q_\alpha)$, où q_α est le α -quantile de la distribution χ_M^2 , avec $\alpha = \lim_{n \rightarrow \infty} h(n)/n$, et h choisi tel que $[(n+p+1)/2] \leq h \leq n$. Afin d'estimer le canal le plus significatif \mathbf{x}_p , le maximum de covariance a été calculé pour des segments de 2 secondes à l'aide d'une fenêtre rectangulaire glissante avec 0.5 seconde de recouvrement, en résolvant

$$\mathbf{x}_p = \max_{[\mathbf{X}]^T} \hat{\boldsymbol{\Sigma}}.$$

Voir Hubert et Debruyne (2010); Rousseeuw et Driessen (1999); Maronna et al. (2019) pour plus de détail sur la méthode d'analyse en maximum de covariance.

2.3 Calcul des paramètres spectraux

Nos analyses préliminaires ont montré que l'utilisation directe des données dans le domaine temporel ne permet pas une caractérisation efficace du phénomène de somnolence. Nous avons donc eu recours au domaine spectral.

Pour chaque état d'alerte et de somnolence, le signal \mathbf{x}_p est partitionné en segments $\mathbf{x}_p(t)$ à l'aide d'une fenêtre rectangulaire glissante sans recouvrement. Pour chaque segment t , nous avons estimé deux paramètres, nommément la fréquence instantanée $f(t)$ et l'entropie spectrale instantanée $H(t)$ selon l'approche suivante.

Soit $S(t, f) = |X_p(t, f)|^2$ le spectrogramme du signal $\mathbf{x}_p(t)$ avec $X_p(t, f)$ la transformée de Fourier discrète de $\mathbf{x}_p(t)$. La distribution de probabilité du spectrogramme à l'instant t est donnée par

$$P(t, m) = \frac{S(t, m)}{\sum_f S(t, f)}$$

On peut ainsi calculer la fréquence instantanée du signal à l'aide de la transformée de Fourier à temps court Boashash (1992a,b)

$$f(t) = \frac{\sum_m m P(t, m)}{\sum_m P(t, m)}$$

Détection de somnolence par analyse de EGG et apprentissage profond

Par ailleurs, on calcule l'entropie spectrale instantanée selon Pan et al. (2009)

$$H(t) = - \sum_m P(t, m) \log_2 P(t, m)$$

Nous avons ainsi transformé le signal du canal pertinent en une séquence de paires de paramètres $(f(t), H(t))$. Cette séquence sera considérée pour l'apprentissage d'un modèle de classification en alerte et somnolence.

2.4 Modèle prédictif

Afin de différencier les états d'alerte et de somnolence, nous avons conçu un classifieur de réseau récurrent à mémoire court et long terme bidirectionnel (BiLSTM). Ce réseau prend en entrée la séquence de paramètres spectraux $\Theta_t = (f(t), H(t))$ extraits à l'étape précédente. Les paramètres ont tous été normalisés selon l'approche z-score, en soustrayant la moyenne et en divisant par l'écart type sur l'ensemble des segments. Selon l'approche standard, l'architecture du réseau consiste en trois portes entrée, sortie et oubli (input, output, forget) (Calin, 2020). La porte d'oubli est la sigmoïde

$$F_t = \sigma(W_F \Theta_t + U_F h_{t-1} + b_F)$$

où les hyper-paramètres W_F and U_F sont des matrices, et b_F un vecteur de biais. σ est la fonction d'activation sigmoïde. Ainsi, $F_t \in (0, 1)$ représente la fraction de l'état passé qui sera oubliée, dépendant de l'état précédent h_{t-1} et de l'entrée Θ_t à l'itération t . De la même manière, la porte d'entrée est définie par

$$I_t = \sigma(W_I \Theta_t + U_I h_{t-1} + b_I)$$

avec les hyper-paramètres W_I, U_I et b_I . Et la porte de sortie

$$O_t = \sigma(W_O \Theta_t + U_O h_{t-1} + b_O)$$

avec ses hyper-paramètres W_O, U_O et b_O . La fonction de mise à jour met à jour sélectivement la mémoire interne du réseau avec

$$c_t = F_T \otimes c_{t-1} + I_t \otimes \tanh(W_c \Theta_t + U_c h_{t-1} + b_c)$$

avec les hyper-paramètres W_c, U_c et b_c , avec $h_t = O_t \otimes \tanh(c_t)$. Le réseau traite une séquence de 10520 paires de paramètres. Il est composé de 100 cellules. Une couche bidirectionnelle a été ajoutée au réseau pour permettre la prise en considération de la dépendance avec les séquences futures. Une couche entièrement connectée permet quant à elle de réduire l'échelle de 100 à deux dimensions. La classification en alerte ou somnolence est obtenue à l'aide d'une couche de fonction exponentielle normalisée.

3 Résultats et discussion

Dans cette section nous rapportons les résultats de notre méthode appliquée au canal TP7 de la banque de données EEG décrites dans la section 2.1. La figure 3 illustre des exemples

de signaux des états alerte et somnolence du canal TP7, dans le domaine temporel. La grande dynamique des signaux EEG empêche la distinction des deux états visuellement. La première phase de notre méthode a établi que le canal TP7 contient les informations pertinentes pour surveiller la somnolence chez les conducteurs. Ce canal situé sur la région tempo-pariétale est lié au lobe associé à la conscience spatiale et la navigation visuelle spatiale (Fig. 1). Par ailleurs, il est connu que la structure physique du cerveau reflète son organisation mentale. En général, les processus mentaux supérieurs se déroulent dans les régions supérieures, alors que les régions inférieures se chargent des fonctions de support (Carter, 2019). Ainsi, notre résultat est tout à fait crédible, du fait que le canal déterminé est lié à la conscience et aux facultés affectives (Postle, 2020). Notre hypothèse est que la mélatonine est responsable de la grande variabilité des formes des ondes du signal dans le domaine temporel (Fig. 3). Cette hormone produite par la glande pinéale aide à réguler les cycles sommeil-éveil. Selon (Carter, 2019), le noyau suprachiasmatique (NSC) situé dans l'hypothalamus joue un rôle clé dans les cycles de sommeil-éveil. Le niveau de lumière est perçu par la rétine et cette information est reliée au NSC qui à son tour envoie un signal à la glande pinéale. Cela entraîne la sécrétion de la mélatonine, qui met le corps en état de sommeil.

Partant de ce résultat, les données du canal TP7 ont été utilisées pour la détection de la somnolence. Les données de tous les sujets ont été traitées selon la méthode décrite dans la section 2, et transformées en séquences spectrales. Les séquences par sujet ont été partitionnées en 80% pour l'entraînement du réseau biLSTM et 20% pour le test (les sujets utilisés pour le test sont entièrement différents des sujets utilisés pour l'entraînement). Ce processus de tirage aléatoire a été répété 100 fois et les performances ont été moyennées. Il est à préciser que nos données sont équilibrées, ayant le même nombre de sujets pour chaque classe et ne nécessite aucune pondération (Fernández et al., 2018; Quintero-Rincón et al., 2019).

Plusieurs métriques sont communément utilisées pour évaluer les performances de classifieurs. Récemment, Ellassad et al. (Ellassad et al., 2020) ont analysé ces métriques dans de nombreuses études et ont trouvé que la précision, la sensibilité et la spécificité sont les plus utilisées. Selon cette étude la précision a été utilisée par 65.85% des 82 études considérées publiées entre 2009 and 2019, alors que la sensibilité et la spécificité ont été utilisées respectivement à 35.36% et 32.92%. En conformité, et pour permettre une lisibilité de nos résultats et leur comparaison avec les méthodes de l'état de l'art, nous rapportons nos résultats en termes de précision, sensibilité et spécificité.

La phase de test de notre méthode a donné une précision de 75% dans la distinction des états d'alerte et de somnolence, avec une sensibilité de 67.7% et une spécificité de 86%. Un test ANOVA a donné une p -value < 0.01 . Le temps de prédiction a été de 1.4 secondes.

Ces résultats ont été comparés avec des méthodes d'apprentissage automatique statistiques, arbre décision, Bayes naïf, machine à support de vecteurs, les k -plus proches voisins, et ensemble d'arbres de décision boostés. Ces méthodes ont donné de meilleures précisions, sensibilités et spécificités, mais un délai de prédiction nettement plus large que celui du biLSTM. La table 1 synthétise ces résultats comparés. Le paramètre k du k -NN a été fixé à \sqrt{N} avec N le nombre de sujets dans les données, dans notre cas $N = 10$ et donc $k \approx 3$. La table 2 rapporte des exemples de canaux utilisés dans différents travaux. Par exemple, dans (Wei et al., 2012) l'analyse relationnelle de Grey (ARG) et l'analyse en composantes principales à noyau (kACP) ont été utilisées pour extraire les canaux pertinents et les données ont été classées à l'aide d'une régression linéaire. Hu (Hu, 2017) a comparé l'efficacité de 4 paramètres en utili-

Détection de somnolence par analyse de EEG et apprentissage profond

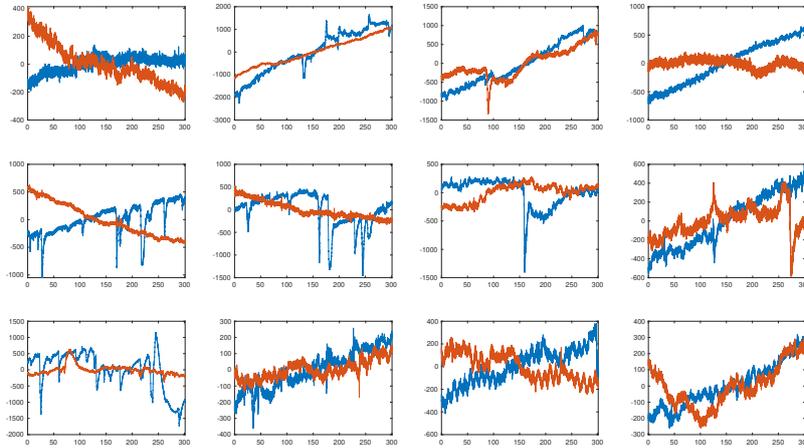


FIG. 3 – Exemples de signaux EEG de l'électrode TP7 correspondant à des états d'alerte (bleu) et somnolence. On observe une grande variabilité du signal dans le domaine temporel.

sant 10 classifieurs différents pour détecter la somnolence. Il a conclu que l'entropie floue avec un classifieur de forêt d'arbres décisionnels donne la meilleure performance avec une précision de 96.6%. Dans (Mu et al., 2017), une combinaison d'entropies avec un classifieur de machine à vecteurs de support a abouti à une précision de 98.75%, sensibilité de 97.50% et spécificité de 96%. Min et al. (Min et al., 2017) ont obtenu une précision de 98.3% avec leur fusion de plusieurs entropies et classifieur par réseau de neurones. Yeo et al. (Yeo et al., 2018) ont utilisé des paramètres du spectre de puissance à partir de 19 canaux avec un SVM. Ils ont rapporté une précision de 99.3% dans la distinction d'états d'alerte et de somnolence. Finalement, Chen et al. (Chen et al., 2009) ont fusionné deux paramètres, un paramètre du réseau cérébrale fonctionnel et un autre de la densité du spectre de puissance. Ils ont utilisé un classifieur de type extreme learning machine (ELM) pour détecter la somnolence, et ont rapporté une précision de 95%, une sensibilité de 95.71% et une spécificité de 94.29%

TAB. 1 – Comparaison des résultats du biLSTM avec des méthodes conventionnelles. Précisions (Pré.) en %, Sensibilité (Sen.) en %, et Spécificité (Spé.) en %, et délai de prédiction (délai) en secondes

Techniques	Pré.	Sen.	Spé.	Délai
biLSTM	75.0	67.7	86.0	1.40
Arbre de décision	84.8	83.0	86.0	6.60
Naïve Bayes	85.1	84.0	86.0	19.80
SVM	84.2	80.0	89.0	16.40
k-NN	85.3	85.0	86.0	5.82
Ensemble d'arbres boostés	85.4	84.0	87.0	6.26

Malgré leur bonne performance, toutes ces méthodes ont une complexité calculatoire élevée, liée principalement à la transformation des données. A l’opposé, notre méthode a des résultats satisfaisants avec un seul canal. Elle est simple à implémenter en temps réel, ce qui est l’objectif ultime dans cette application.

4 Conclusions

Cet article a présenté la mise en œuvre complète d’un processus de science de données pour élaborer un modèle prédictif de la somnolence chez les conducteurs à partir de données EEG. La méthode a consisté à analyser les signaux EEG à l’aide d’une méthode d’analyse statistique robuste par maximum de covariance pour déterminer un canal unique porteur de l’information utile à la tâche. Cette analyse a abouti à l’identification du canal TP7 situé dans la région tempo-pariétale comme étant le plus pertinent. Cette région correspondant à la conscience spatiale et à la navigation visuelle spatiale, très pertinente pour surveiller la somnolence, rend le résultat très probant.

Une seconde contribution de l’article est la transformation de la série temporelle des signaux EEG en séquences de paramètres spectraux. Ces paramètres révèlent les caractéristiques relatives des états d’alerte et de somnolence pendant la conduite. Un classifieur de type réseau de neurones récurrent à mémoire de court et long terme a été entraîné avec ces séquences de paramètres. Des expérimentations ont été faites avec des données réelles avec 24 signaux EEG obtenus de Jiangxi University of Technology (Min et al., 2017). Les résultats ont montré une précision de 75% à distinguer les états d’alerte et de somnolence, avec un délai de prédiction de 1.4 seconde. L’avantage principale de la méthode proposée est sa simplicité lui conférant la capacité d’être implémentée en temps réel. En plus, l’utilisation d’un canal unique rend la mise en œuvre pratique plus facile.

La limitation principale de la méthode est le volume de données faible. Une des perspectives de ce travail est de développer une méthode d’augmentation de données à l’aide d’un réseau antagoniste génératif (GAN) (Radford et al., 2016). Une autre perspective est d’intégrer la phase de transformation spectrale dans le réseau d’apprentissage profond en utilisant and LSTM convolutionnel (Abdelhameed et al., 2018).

Acknowledgement

Les auteurs remercient María Eugenia Fontecha pour ses commentaires utiles sur une versions préliminaire de cet article.

Références

- Abdelhameed, A. M., H. G. Daoud, et M. Bayoumi (2018). Deep convolutional bidirectional lstm recurrent neural network for epileptic seizure detection. In *2018 16th IEEE International New Circuits and Systems Conference (NEWCAS)*, pp. 139–143. IEEE.
- BalasuBramanian, V. et R. Bhardwaj (2018). Can cECG be an unobstrusive surrogate to determine cognitive state of driver? *Transportation Part F* 58, 797–806.

Détection de somnolence par analyse de EGG et apprentissage profond

TAB. 2 – *Quelques exemples de canaux utilisés dans différents travaux. La plupart des méthodes donnent une bonne précision (Pré.). Les techniques de sélection de canaux sont diverses : Robust analysis (RUA), Grey relational analysis (GRA), Kernel Principal Component Analysis (kPCA). Various features : Sample Entropy (SA), Spectral entropy (SE), Approximate entropy (AE), Fuzzy entropy (FE), Entropy fusion (EF), Power spectral density (PSD), Functional brain network (FBN). And different classifiers : Long Short Term Memory (LSTM), Random Forest (RF), Support vector machine (SVM), Back propagation Neural network (BPNN), Extreme learning machine (ELM).*

Canaux	Méthode	Classifier	Pré.	Ref.
TP7	RA	biLSTM	75.0%	our
FP1, O1	GRA+KPCA	LRE	92.3%	(Wei et al., 2012)
CP4	SE+FE+ AE+PE	RF	96.6%	(Hu, 2017)
T5, TP7, TP8, FP1	SE+AE+SE+FE	SVM	98.7%	(Mu et al., 2017)
T6, P3, TP7, O1, Oz, T4, T5, FCz, FC3, CP3	EF	BP	98.3%	(Min et al., 2017)
tous	PSD	SVM	99.3%	(Yeo et al., 2018)
tous	FBN-PSD	ELM	95.0%	(Chen et al., 2009)

- Boashash, B. (1992a). Estimating and interpreting the instantaneous frequency of a signal-part 1 : Fundamentals. *Proceedings of the IEEE* 80, 520–538.
- Boashash, B. (1992b). Estimating and interpreting the instantaneous frequency of a signal-part 2 : algorithms and applications. *Proceedings of the IEEE* 80(4), 540–568.
- Borg, G. (1990). Psychophysical scaling with applications in physical work and the perception of exertion. *Scandinavian Journal of Work* 16(1), 55–58.
- Calin, O. (2020). *Deep learning architectures. A mathematical approach*. Springer.
- Carter, R. (2019). *The Human Brain Book : An illustrated guide to its structure, function, and disorders*. Penguin.
- Chen, J., H. Wang, C. Hua, et E. P. V. Wilder-Smith (2009). Electroencephalography based fatigue detection using a novel feature fusion and extreme learning machine. *Cognitive Systems Research* 52, 115–124.
- Elassad, Z. E. A., H. Mousannif, H. A. Moatassime, et A. Karkouch (2020). The application of machine learning techniques for driving behavior analysis : A conceptual framework and a systematic literature review. *Engineering Applications of Artificial Intelligence* 87(10331), 2.
- Fares, A., S.-h. Zhong, et J. Jiang (2019). EEG-based image classification via a region-level stacked bi-directional deep learning framework. *BMC medical informatics and decision making* 19(6), 1–11.
- Fernández, A., S. García, M. Galar, R. C. Prati, B. Krawczyk, et F. Herrera (2018). *Learning from Imbalanced Data Sets*, Volume 11. Springer.

- Hochreiter, S. et J. Schmidhuber (1997). Long short-term memory. *Neural computation* 9(8), 1735–1780.
- Horne, J. et L. Reyner (1995). Sleep related vehicle accidents. *BMJ Clinical Research* 310(6979), 565–567.
- Hou, Y., S. Jia, S. Zhang, X. Lun, Y. Shi, Y. Li, H. Yang, R. Zeng, et J. Lv (2020). Deep feature mining via attention-based bilstm-gcn for human motor imagery recognition. *ArXiv*, 1–8. arXiv :2005.00777.
- Hu, J. (2017). Comparison of different features and classifiers for driver fatigue detection based on a single EEG channel. *Computational and Mathematical Methods in Medicine* 2017(51095), 30.
- Hubert, M. et M. Debruyne (2010). Minimum covariance determinant. *Wiley Interdisciplinary Reviews : Computational statistics* 2(1), 36–43.
- Jap, B. T., S. Lal, P. Fischer, et E. Bekiaris (2009). Using EEG spectral components to assess algorithms for detecting fatigue. *Expert Systems with Applications* 36(2), 2352–2359.
- Lal, S. et A. Craig (2002). Driver fatigue : Electroencephalography and psychological assessment. *Psychophysiology* 39(3), 313–321.
- Lal, S. K., A. Craig, P. Boord, L. Kirkup, et H. Nguyen (2003). Development of an algorithm for an EEG-based driver fatigue countermeasure. *Journal of Safety Research* 34(3), 321–328.
- Lawhern, V., S. Kerick, et K. Robbins (2013). Detecting alpha spindle events in EEG time series using adaptive autoregressive models. *BMC Neuroscience* 14(101), 1–9.
- Lee, K. A., G. Hicks, et G. Nino-Murcia (1991). Validity and reliability of a scale to assess fatigue. *Psychiatry Research* 36(3), 291–298.
- Li, G. et J. Jung (2020). Maximum marginal approach on EEG signal preprocessing for emotion detection. *Applied Sciences* 10(7677), 1–11.
- Maronna, R. A., R. D. Martin, V. J. Yohai, et M. Salibián-Barrera (2019). *Robust statistics Theory and methods with R*. Wiley.
- Min, J., P. Wang, et J. Hu (2017). Driver fatigue detection through multiple entropy fusion analysis in an EEG-based system. *Plos One* 12(12), e0188756.
- Molinari, L. et G. Dumermuth (1986). Robust multivariate spectral analysis of the EEG. *Neuropsychobiology* 15(3-4), 208–218.
- Mu, Z., J. Hu, et J. Min (2017). Driver fatigue detection system using electroencephalography signals based on combined entropy features. *Applied Sciences* 7(2), 150–167.
- Olive, D. J., D. J. Olive, et Chernyk (2017). *Robust Multivariate Analysis*. Springer.
- Pan, Y., J. Chen, et X. Li (2009). Spectral entropy : a complementary index for rolling element bearing performance degradation assessment. *Proceedings of the Institution of Mechanical Engineering Science, Part C : Journal of Mechanical Engineering Science* 223(5), 1223–1231.
- Postle, B. R. (2020). *Essentials of Cognitive Neuroscience*. John Wiley & Sons.
- Quintero-Rincón, A., M. Flugelman, J. Prendes, et C. d’Giano (2019). Study on epileptic seizure detection in EEG signals using largest lyapunov exponents and logistic regression.

- Revista Argentina de Bioingeniería* 23(2), 17–24.
- Quintero-Rincón, A., M. Pereyra, C. D’Giano, M. Risk, et H. Batatia (2018). Fast statistical model-based classification of epileptic EEG signals. *Biocybernetics and Biomedical Engineering* 38(4), 877–889.
- Quintero-Rincón, A., J. Prendes, M. Pereyra, H. Batatia, et M. Risk (2016). Multivariate bayesian classification of epilepsy EEG signals. In *2016 IEEE 12th Image, Video, and Multidimensional Signal Processing Workshop (IVMSP)*, pp. 1–5. IEEE.
- Radford, A., L. Metz, et S. Chintala (2016). Unsupervised representation learning with deep convolutional generative adversarial networks. In Y. Bengio et Y. LeCun (Eds.), *4th International Conference on Learning Representations*.
- Rousseeuw, P. J. et K. V. Driessen (1999). A fast algorithm for the minimum covariance determinant estimator. *Technometrics* 41(3), 212–223.
- Sameni, R. et E. Seraj (2017). A robust statistical framework for instantaneous electroencephalogram phase and frequency estimation and analysis. *Physiological Measurement* 38(12), 2141–2163.
- Schomer, D. L. et F. H. L. da Silva (Eds.) (2017). *Niedermeyer’s Electroencephalography : Basic Principles, Clinical Applications, and Related Fields* (7th ed.). Oxford University Press.
- Schuster, M. et K. Paliwal (1997). Bidirectional recurrent neural networks. *IEEE Transactions on Signal Processing* 45(11), 2673–2681.
- Simon, M., E. A. Schmidt, W. E. Kincses, M. Fritzsche, A. Bruns, C. Aufmuth, M. Bogdan, W. Rosenstiel, et M. Schrauf (2011). EEG alpha spindle measures as indicators of driver fatigue under real traffic conditions. *Clinical Neurophysiology* 122(6), 1168–1178.
- Uehara, T., M. Sartori, T. Tanaka, et S. Fiori (2017). Robust averaging of covariances for EEG recordings classification in motor imagery brain-computer interfaces. *Neural Computation* 29(6), 1631–1666.
- Wei, L., H. Qi-chang, F. Xiu-min, et F. Zhi-min (2012). Evaluation of driver fatigue on two channels of EEG data. *Neuroscience Letters* 506(2), 235–239.
- Yang, J., X. Huang, H. Wu, et X. Yang (2020). EEG-based emotion classification based on bidirectional long short-term memory network. *Procedia Computer Science* 174, 491–504.
- Yeo, M. V. M., X. Li, K. Shen, et E. P. V. Wilder-Smith (2018). Can svm be used for automatic EEG detection of drowsiness during car driving? *Safety Science* 47(1), 715–728.
- Yong, X., R. K. Ward, et G. E. Birch (2008). Robust common spatial patterns for EEG signal preprocessing. In *30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 2087–2090. IEEE.

Annexe : Lobes du cerveau

Dans cette annexe courte, nous fournissons quelques informations sur la structure du cerveau. Ces informations sont nécessaires pour interpréter et évaluer les résultats de n’importe quel modèle d’apprentissage automatique sur l’EEG. Dans notre cas, il est important d’inter-

préter la localisation du canal trouvé pertinent par notre analyse statistique pour la surveillance de la somnolence chez les conducteurs.

La tâche principale du cerveau est d'aider à garder l'organisme dans un état optimal étant donné l'environnement afin de maximiser les chances de survie. Lors de ce processus, le cerveau classe les informations pertinentes arrivant comme des impulsions électriques depuis les neurones au niveau des organes sensoriels. Cette activité électrique est amplifiée et représentée dans les régions cérébrales frontale, pariétale, occipitale et temporale. Quand cette activité persiste une durée significative, il en résulte une expérience consciente (Carter, 2019).

La figure 1 montre les positions d'un système EEG du standard international 10-20. Les électrodes sont étiquetées en fonction du lobe lié à leur position et à leur l'hémisphère. Par exemple F = frontal, P = pariétal, O = occipital, T = temporal, C = central, z : la fissure longitudinale, nombres impairs pour la gauche et nombres pairs pour la droite.

Les fonctions principales du lobe frontal sont le contrôle du mouvement, le raisonnement, l'émotion consciente, le langage, la planification, la pensée, le jugement, et la décision. Le lobe pariétal est associé à l'intégration des stimuli sensoriels et perceptuels aussi bien conscient qu'inconscient, comme le calcul spatial, l'orientation du corps, et l'attention. Le lobe pariétal est lié à la mémoire, l'ouïe, le langage, l'émotion, et la navigation visuelle spatiale. Le lobe occipital est responsable du traitement visuel par intégration des informations visuelles aussi bien conscientes qu'inconscientes. Le sillon central sépare les lobes frontal et pariétal. Il est relié au cortex moteur primaire et au cortex somesthésique primaire. Le sillon latéral sépare les lobes latéral et frontal du lobe temporal. Il est associé à la production du langage. Se référer à (Schomer et da Silva, 2017) pour plus d'information sur la structure du cerveau.

Summary

Driver fatigue is a major cause of traffic accidents. Electroencephalogram (EEG) is considered one of the most reliable predictors of fatigue. This paper proposes a novel, simple and fast method for driver fatigue detection that can be implemented in real-time by using a single channel on the scalp. The study consists of two objectives. First, determine the most significant EEG channel to monitor fatigue using maximum covariance analysis. And second, develop a machine learning method to detect fatigue from this single channel using a Long Short-Term Memory (LSTM) deep learning model based on spectral features. Experiments with 12 EEG signals were conducted to discriminate the fatigue stage from the alert stage. Our main discovery was that the most significant channel found (TP7) is located in the left tempo-parietal region where spatial awareness and visual-spatial navigation are shared. This channel is also related to the cautiousness faculty. In addition, despite the small dataset, the proposed method yielded 75% accuracy for fatigue prediction with a 1.4-second delay. These promising results provide new insights on relevant data for monitoring driver fatigue.

Keywords: Robust analysis, biLSTM, Driver fatigue, EEG