

Statistiques robustes et réseaux profonds pour détecter la somnolence à partir de signaux EEG

Antonio Quintero-Rincón*, Hadj Batatia**

*Department of Data Science, Department of Computer Sciences
Data Science and AI Lab
Catholic University of Argentina (UCA), Buenos Aires, Argentina
antonioquintero@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 cet état cérébral. Cet article propose une nouvelle méthode de détection de somnolence à l'aide d'une seule électrode, avec un potentiel d'implémentation temps réel. L'article présente d'abord une méthode originale pour déterminer le canal EEG le plus pertinent pour surveiller la somnolence, en utilisant l'analyse de covariance maximale. La seconde contribution consiste à développer une méthode d'apprentissage profond avec les signaux du canal déterminé. L'approche procède par extraction des caractéristiques spectrales du signal. Ces caractéristiques sont utilisées avec un modèle de réseau récurrent à mémoire court et long terme (LSTM) pour détecter les états de somnolence et d'alerte. Notre résultat principal est que le canal TP7, situé dans la région temporo-pariétale gauche, est le plus significatif. 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. Malgré le faible volume de données, la méthode proposée permet de prédire la somnolence avec une précision de 75% et un délai moyen de 1.4 secondes. Ces résultats prometteurs mettent en lumière des facteurs importants à considérer pour la surveillance de la somnolence.

1 Introduction

L'état de somnolence est souvent dû au comportement de privation de sommeil, à des facteurs circadiens ou à des troubles du sommeil (Philip et Sagaspe, 2011). Chez les conducteurs, la somnolence est une cause majeure d'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 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. 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 niveau de conscience. 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 thêta (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. (Li 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 et al. (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 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 (Elamrani Abou El Assad et al., 2020; Lambay et al., 2024; El-Nabi et al., 2024). Des études récentes (Jacobé de Naurois et al., 2019; Du et al., 2022; Bakker et al., 2022; He et al., 2024) ont démontré le potentiel de la fusion de caractéristiques multimodales dans la détection de la fatigue au volant. Lan et al. (Lan et al., 2024) ont récemment étudié la fusion

d'informations EEG et de mouvement du véhicule pour détecter la fatigue des conducteurs. Par ailleurs, bien que la plupart des études sur la surveillance de la fatigue au volant dépendent de données collectées en laboratoire dans des conditions contrôlées, des efforts appréciables ont été faits pour exploiter des expériences réalistes de conduite (Persson et al., 2021; Bakker et al., 2022) ou même les données de conduite naturelle (He et al., 2024).

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., 2029; 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 concerne 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. Nous proposons d'abord une approche de statistique robuste par analyse en maximum de covariance pour déterminer le canal EEG le plus pertinent à la somnolence. Puis, nous développons un réseau BiLSTM, utilisant des paramètres spectraux (Hochreiter et Schmidhuber, 1997; Schuster et Paliwal, 1997) du canal déterminé, pour différencier les états d'alerte et de somnolence. Plus précisément, on transforme la série temporelle de données EEG en une séquence de paramètres pour alimenter le réseau BiLSTM. Nous avons appliqué la méthode proposée à 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 la 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 toutes 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 3 étapes : la sélection du canal pertinent (section 2.1), la transformation spectrale des données (section 2.2), et la détection de somnolence par un modèle prédictif (section 2.3). Dans la section 3, nous décrivons les données expérimentales (section 3.1), puis nous analysons et




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.

discutons les résultats obtenus. Finalement, la section 4 esquisse des conclusions et des perspectives.

2 Méthode proposée

Une méthode en trois étapes a été mise en œuvre pour cette étude (Fig.2). La première étapes consiste à prétraiter les données pour sélectionner l'électrode la plus pertinente pour l'analyse de la somnolence. Cela est fait à l'aide d'une méthode d'analyse statistique robuste. La seconde étape consiste à transformer le signal du canal sélectionné en une séquence de paramètres spectraux. Cela permet d'un côté de réduire la dimension des données, et de l'autre côté de révéler les caractéristiques spectrales de la somnolence. La troisième étape consiste à apprendre un modèle prédictif pour détecter les états de somnolence. Ces étapes sont présentées dans les sections suivantes.




FIG. 2 – Etapes de notre méthode.

2.1 Sélection de l'électrode pertinente

Afin de sélectionner l'électrode la plus pertinente, nous avons considéré les éléments suivants, rapportés dans la littérature. D'abord, il a été établi que l'état d'alerte se caractérise par

une activité cérébrale assez intense (Huber et al., 2013). Cela correspondrait à l'observation d'une variabilité importante dans les signaux EEG. D'un autre côté, il est bien connu que l'état de sommeil est caractérisé par des oscillations lentes (Diekelmann et Born, 2010). Cela correspondrait à une faible variabilité dans l'EEG. L'état de somnolence est plus complexe, et différent des deux états d'alerte et de sommeil. L'inspection visuelle des signaux EEG ne montre aucune différence notable entre les états d'alerte et de somnolence chez les conducteurs. Nous considérons ainsi que la somnolence est un état intermédiaire entre alerte et sommeil. Notre hypothèse est que cet état correspondrait à des signaux EEG avec une large variabilité, tout comme l'alerte. Partant de ce constat, nous considérons que le canal contenant le plus d'information dans l'état de somnolence serait celui ayant une covariance maximale. Nous avons donc mis en œuvre une méthode d'analyse de maximum de covariance pour identifier ce canal.

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 l'indicatrice, $*$ est le complexe conjugué, et μ 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

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

L'algorithme 1 met en œuvre cette méthode pour sélectionner le canal pertinent. Voir Hubert et Debruyne (2010); Rousseeuw et Driessen (1999); Hubert et al. (2018a); Maronna et al. (2019) pour plus de détails sur la méthode d'analyse de covariance maximale.

2.2 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 la somnolence. Cela est due à la dynamique très large des signaux EEG. Les caractéristiques classiques de type morphologiques et statistiques ne sont donc pas très utiles. 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

```

Input :  $X^p$ ,  $p=1..P$ ;
for each patient  $p$  do
    Partition  $X$  using a sliding window ;
    Let  $X_s^p$ ,  $s=1..S$  the segments;
    for each segment  $s$  do
        |  $(\hat{\mu}_s^p, \hat{\Sigma}_s^p) \leftarrow \text{MCD}(X_s^p)$ ;
    end
     $\hat{\Sigma}^p \leftarrow \text{Average}(\hat{\Sigma}_s^p)$ ;
    for each channel  $m$  do
        |  $\hat{\Sigma}_m^p \leftarrow \max(\hat{\Sigma}^p)$ ;
    end
end
for each channel  $m$  do
    |  $c_m \leftarrow \sum_{i=1}^P [\hat{\Sigma}_m^p(\text{fatigue}) > \hat{\Sigma}_m^p(\text{alert})]$ ; [] Inversion fonction;
end
channel  $\leftarrow \arg \max_m c_m$ ;
Algorithme 1 : Algorithme de sélection du canal pertinent
    
```

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 $x_p(t)$ avec $X_p(t, f)$ la transformée de Fourier discrète de $x_p(t)$. 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, 1992b) and (Boashash, 1992)

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

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.

2.3 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, dit LSTM (Fig.3). Ce réseau prend en

entrée la séquence de paramètres spectraux $\mathbf{x}_t = (f(t), H(t))$ 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 oublie (input, output, forget) (Calin, 2020). La porte d'oublie est la sigmoïde

$$f_t = \sigma(V_f \mathbf{x}_t + U_f h_{t-1} + b_f)$$

où les hyperparamètres V_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 $\mathbf{x}_t$ à l'itération t . De la même manière, la porte d'entrée est définie par

$$i_t = \sigma(V_i \mathbf{x}_t + U_i h_{t-1} + b_i)$$

avec les hyper-paramètres V_i, U_i et b_i . La porte intermédiaire est définie par

$$\hat{c}_t = \tanh(V_c \mathbf{x}_t + U_c h_{t-1} + b_c)$$

avec les hyperparamètres V_c, U_c et b_c . Finalement, la porte de sortie est définie par

$$o_t = \sigma(V_o \mathbf{x}_t + U_o h_{t-1} + b_o)$$

avec ses hyperparamètres V_o, U_o et b_o . La mise à jour sélective de la mémoire interne du réseau se fait à l'aide de la fonction

$$\begin{aligned} c_t &= f_t \otimes c_{t-1} + i_t \otimes \hat{c}_t, \text{ et} \\ h_t &= O_t \otimes \tanh(c_t). \end{aligned}$$

Dans notre étude, 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

La méthode proposée a été appliquée à une base de données publique décrite dans la section 3.1. Nous rapportons d'abord les résultats de l'analyse statistique robuste. Puis nous présentons les résultats de la détection de somnolence et nous les comparons aux résultats de plusieurs méthodes de l'état de l'art.

3.1 Description des données

Une base de données composée de 12 signaux unipolaires correspondant à des états de somnolence et de 12 autres d'alerte a été fournie par (Min et al., 2017). Les sujets concernés




FIG. 3 – Architecture du réseau récurrent à mémoire court et long terme. Das ce schéma, la matrice de paramètres $W_{\bullet}$ est la juxtaposition des matrices $V_{\bullet}$ et $U_{\bullet}$. x_t est le vecteur de paramètres pour la fenêtre t .

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 signaux 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 d'une durée de 5 minutes, numérisés avec la fréquence $fs = 1000$ Hz.

3.2 Canal pertinent

L'analyse statistique robuste a montré que TP7 est le canal qui correspond à la variance maximale dans l'état de somnolence, chez le plus grand nombre de sujets (Tab.1). 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. 4). 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.

Channel	C_m	Channel	C_m
FP1	7	C4	6
FP2	6	T4	6
F7	4	TP7	10
F3	6	CP3	8
FZ	7	CPZ	4
F4	5	CP4	6
F8	5	TP8	5
FT7	5	T5	7
FC3	6	P3	7
FCZ	6	PZ	6
FC4	6	P4	8
FT8	5	T6	5
T3	7	O1	7
C3	7	OZ	7
CZ	6	O2	5

TAB. 1 – Résultats de l’analyse en maximum de covariance. La colonne C_m indique le score moyenne (en nombre de patients) obtenu par chaque canal. Noter que la base de données compte 12 patients.

3.3 Détection de somnolence

Dans cette section, nous rapportons les résultats de notre méthode de détection de somnolence appliquée à la base de données considérée. Partant du résultat de la sélection du canal pertinent, les données du canal TP7 ont été utilisées pour la détection de la somnolence. La figure 4 illustre des exemples de signaux des états d’alerte et de somnolence du canal TP7. On peut constater que la grande dynamique des signaux EEG empêche la distinction visuelle des deux états dans le domaine temporel.

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 avec le même nombre de sujets pour chaque classe et ne nécessitent 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. (Elamrani Abou 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 la 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 moyen 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, en termes de sensibilités et spécificités, mais un délai de prédiction nettement plus large que celui du biLSTM. La table 2 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




FIG. 4 – 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. Ce constat s'applique aux 12 sujets d'étude.

table 3 rapporte des exemples de canaux utilisés dans différents travaux. Par exemple, dans Li 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 utilisant 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.,

2009) 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., 2018) 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%

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

TAB. 2 – 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

Malgré leurs bonnes performances, 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 Conclusion

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 des signaux EEG en en série temporelles de 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 obtenues 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 moyen 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 un modèle LSTM convolutionnel (Abdelhameed et al., 2018). Finalement, des algorithmes récents de classification des séries temporelles (Middlehurst et al., 2024), comme MultiROCKET+Hydra (Dempster et al., 2020, 2023), HIVE-COTEv2 (Middlehurst et al., 2021), et la régression extrinsèque (Foumani et al., 2024) seront étudiés pour cette application.

TAB. 3 – *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). Divers features : Sample Entropy (SA), Spectral entropy (SE), Approximate entropy (AE), Fuzzy entropy (FE), Entropy fusion (EF), Power spectral density (PSD), Functional brain network (FBN). Et différents classifieurs : Long Short Term Memory (LSTM), Random Forest (RF), Support vector machine (SVM), Back propagation Neural network (BPNN), Extreme learning machine (ELM).*

Canaux	Méthode	Classifieur	Pré.	Ref.
TP7	RA	biLSTM	75.0%	our
FP1, O1	GRA+KPCA	LRE	92.3%	(Li 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., 2009)
tous	FBN-PSD	ELM	95.0%	(Chen et al., 2018)

Références

- Hou, Y., S. Jia, S. Zhang, X. Lun, Y. Shi, Y. Li, H. Yang, R. Zeng, et J. Lv (2029). Deep feature mining via attention-based BiLSTM-GCN for human motor imagery recognition. *Frontiers in Bioengineering and Biotechnology* 9, 1–8, doi:10.3389/fbioe.2021.706229.
- Lambay, A., Y. Liu, P. L. Morgan, et Z. Ji (2024). Machine learning assisted human fatigue detection, monitoring, and recovery : A review. *Digital Engineering* 1, 100004, doi:10.1016/j.dte.2024.100004.
- El-Nabi, S. A., W. El-Shafai, E.-S. M. El-Rabaie, K. F. Ramadan1, F. E. A. El-Samie1, et S. Mohsen (2024). Machine learning and deep learning techniques for driver fatigue and drowsiness detection : A review. *Multimedia Tools and Applications* 83, 9441–9477, doi:10.1007/s11042-023-15054-0.

- He, C., P. Xu, X. Pei, Q. Wang, Y. Yue, et C. Han (2024). Fatigue at the wheel : A non-visual approach to truck driver fatigue detection by multi-feature fusion. *Accident Analysis & Prevention* 199, 107511, doi:10.1016/j.aap.2024.107511.
- Lan, Z., J. Zhao, P. Liu, C. Zhang, N. Lyu, et L. Guo (2024). Driving fatigue detection based on fusion of EEG and vehicle motion information. *Biomedical Signal Processing and Control* 92, 106031, doi:10.1016/j.bspc.2024.106031.
- Foumani, N. M., L. Miller, C. W. Tan, G. I. Webb, G. Forestier, et M. Salehi (2024). Deep learning for time series classification and extrinsic regression : A current survey. doi:10.1145/3649448.
- Middlehurst, M., P. Schäfer, et A. Bagnall (2024). Bake off redux : a review and experimental evaluation of recent time series classification algorithms. *Data Mining and Knowledge Discovery* 38, 1958–2031.
- Dempster, A., D. F. Schmidt, et G. I. Webb (2023). Hydra : competing convolutional kernels for fast and accurate time series classification. *Data Mining and Knowledge Discovery* 37, 1779–1805, doi:10.1007/s10618-023-00939-3.
- Du, G., L. Zhang, K. Su, X. Wang, S. Teng, et P. X. Liu (2022). A multimodal fusion fatigue driving detection method based on heart rate and perclos. *IEEE Transactions on Intelligent Transportation Systems* 23(11), 21810–21820, doi:10.1109/TITS.2022.3176973.
- Bakker, B., B. Zabłocki, A. Baker, V. Riethmeister, B. Marx, G. Iyer, A. Anund, et C. Ahlström (2022). A multi-stage, multi-feature machine learning approach to detect driver sleepiness in naturalistic road driving conditions. *IEEE Transactions on Intelligent Transportation Systems* 23(5), 4791–4800, doi:10.1109/TITS.2021.3090272.
- Middlehurst, M., J. James Large, M. Flynn, J. Lines, A. Bostrom, et A. Bagnal (2021). Hive-cote 2.0 : a new meta ensemble for time series classification. *Data Mining and Knowledge Discovery* 110, 3211–3243.
- Persson, A., H. Jonasson, I. Fredriksson, U. Wiklund, et C. Ahlström (2021). Heart rate variability for classification of alert versus sleep deprived drivers in real road driving conditions. *IEEE Transactions on Intelligent Transportation Systems* 22(6), 3316–3325, doi:10.1109/TITS.2020.2981941.
- Dempster, A., D. F. Schmidt, et G. I. Webb (2020). Minirocket : A very fast (almost) deterministic transform for time series classification. *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*, doi:10.1145/3447548.3467231.
- Li, G. et J. J. Jung (2020). Maximum marginal approach on EEG signal preprocessing for emotion detection. *Applied Sciences* 10(21), 1–11, doi:10.3390/app10217677.
- Postle, B. R. (2020). *Essentials of Cognitive Neuroscience*. John Wiley & Sons.
- 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, doi:10.1016/j.procs.2020.06.117. 2019 International Conference on Identification, Information and Knowledge in the Internet of Things.
- Calin, O. (2020). *Deep learning architectures. A mathematical approach*. Springer.
- Elamrani Abou El Assad, Z., H. Mousannif, H. Al 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, 103312, doi:10.1016/j.engappai.2019.103312.
- 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.
- Maronna, R. A., R. D. Martin, V. J. Yohai, et M. Salibián-Barrera (2019). *Robust statistics Theory and methods with R*. Wiley.
- Carter, R. (2019). *The Human Brain Book : An illustrated guide to its structure, function, and disorders*. Penguin.
- 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, doi:10.1186/s12911-019-0967-9.
- Jacobé de Naurois, C., C. Bourdin, A. Stratulat, E. Diaz, et J.-L. Vercher (2019). Detection and prediction of driver drowsiness using artificial neural network models. *Accident Analysis Prevention* 126, 95–104, doi:10.1016/j.aap.2017.11.038. 10th International Conference on Managing Fatigue : Managing Fatigue to Improve Safety, Wellness, and Effectiveness.
- Hubert, M., M. Debruyne, et P. J. Rousseeuw (2018a). Minimum covariance determinant and extensions. *WIREs Computational Statistics* 10(3), e1421, doi:10.1002/wics.1421.
- Fernández, A., S. García, M. Galar, R. C. Prati, B. Krawczyk, et F. Herrera (2018). *Learning from Imbalanced Data Sets*, Volume 11. Springer.
- 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, doi:10.1016/j.bbe.2018.08.002.
- Chen, J., H. Wang, et C. Hua (2018). Electroencephalography based fatigue detection using a novel feature fusion and extreme learning machine. *Cognitive Systems Research* 52, 715–728, doi:10.1016/j.cogsys.2018.08.018.
- Abdelhameed, A. M., H. G. Daoud, et M. Bayoumi (2018). Deep convolutional bi-directional LSTM recurrent neural network for epileptic seizure detection. In *2018 16th IEEE International New Circuits and Systems Conference (NEWCAS)*, pp. 139–143. doi:10.1109/NEWCAS.2018.8585542.
- Balasubramanian, V. et R. Bhardwaj (2018). Can cECG be an unobtrusive surrogate to determine cognitive state of driver? *Transportation Research Part F : Traffic Psychology and Behaviour* 58, 797–806, doi:10.1016/j.trf.2018.07.011.
- 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, doi:10.1088/1361-6579/aa93a1.
- Olive, D. J., D. J. Olive, et Chernyk (2017). *Robust Multivariate Analysis*. Springer.
- 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, doi:10.1162/NECO_a_00963.
- 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, doi:10.1093/med/9780190228484.001.0001.
- 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, doi:10.1371/journal.pone.0188756.
- 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, doi:10.3390/app7020150.
- 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(1), 5109530, doi:10.1155/2017/5109530.
- 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*.
- 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, doi:10.1109/IVMSPW.2016.7528180.
- Huber, R., H. Mäki, M. Rosanova, S. Casarotto, P. Canali, A. G. Casali, G. Tononi, et M. Massimini (2013). Human cortical excitability increases with time awake. *Cerebral cortex* 23(2), 1–7, doi:10.1093/cercor/bhs014.
- 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, doi:10.1186/1471-2202-14-101.
- Li, W., Q. chang He, X. min Fan, et Z. min Fei (2012). Evaluation of driver fatigue on two channels of EEG data. *Neuroscience Letters* 506(2), 235–239, doi:10.1016/j.neulet.2011.11.014.
- Philip, P. et P. Sagaspe (2011). Sommeil et accidents. *Bulletin de l'Académie Nationale de Médecine* 195(7), 1635–1643, doi:10.1016/S0001-4079(19)31958-2.
- 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, doi:10.1016/j.clinph.2010.10.044.
- Hubert, M. et M. Debruyne (2010). Minimum covariance determinant. *WIREs Computational Statistics* 2(1), 36–43, doi:10.1002/wics.61.
- Diekelmann, S. et J. Born (2010). The memory function of sleep. *Nature Reviews Neuroscience* 11(2), 114–126, doi:10.1038/nrn2762.
- 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, Part 1), 2352–2359, doi:10.1016/j.eswa.2007.12.043.
- Pan, Y. N., J. Chen, et X. L. Li (2009). Spectral entropy : A complementary index for rolling element bearing performance degradation assessment. *Proceedings of the Institution of Mechanical Engineers, Part C : Journal of Mechanical Engineering Science* 223(5), 1223–1231, doi:10.1243/09544062JMES1224.

- Yeo, M. V., X. Li, K. Shen, et E. P. Wilder-Smith (2009). Can SVM be used for automatic EEG detection of drowsiness during car driving? *Safety Science* 47(1), 115–124, doi:10.1016/j.ssci.2008.01.007.
- 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, doi:10.1109/IEMBS.2008.4649604.
- 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, doi:10.1016/s0022-4375(03)00027-6.
- Lal, S. et A. Craig (2002). Driver fatigue : Electroencephalography and psychological assessment. *Psychophysiology* 39(3), 313–321, doi:10.1017/s0048577201393095.
- Rousseeuw, P. J. et K. V. Driessen (1999). A fast algorithm for the minimum covariance determinant estimator. *Technometrics* 41(3), 212–223, doi:10.2307/1270566.
- Hochreiter, S. et J. Schmidhuber (1997). Long short-term memory. *Neural computation* 9(8), 1735–1780, doi:10.1162/neco.1997.9.8.1735.
- Schuster, M. et K. Paliwal (1997). Bidirectional recurrent neural networks. *IEEE Transactions on Signal Processing* 45(11), 2673–2681, doi:10.1109/78.650093.
- Horne, J. et L. Reyner (1995). Sleep related vehicle accidents. *BMJ Clinical Research* 310(6979), 565–567, doi:10.1136/bmj.310.6979.565.
- Boashash, B.-. (1992). Estimating and interpreting the instantaneous frequency of a signal. II. Algorithms and applications. *Proceedings of the IEEE* 80(4), 540–568, doi:10.1109/5.135378.
- Boashash, B.-. (1992b). Estimating and interpreting the instantaneous frequency of a signal. I. Fundamentals. *Proceedings of the IEEE* 80(4), 520–538, doi:10.1109/5.135376.
- 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, doi:10.1016/0165-1781(91)90027-m.
- Borg, G. (1990). Psychophysical scaling with applications in physical work and the perception of exertion. *Scandinavian Journal of Work* 16(1), 55–58, doi:10.5271/sjweh.1815.
- Molinari, L. et G. Dumermuth (1986). Robust multivariate spectral analysis of the EEG. *Neuropsychobiology* 15(3-4), 208–218, doi:10.1159/000118265.

Annexe : Lobes du cerveau

Dans cette annexe, nous fournissons quelques informations sur la structure du cerveau utiles à la lecture de l'article. 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'interpréter 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 classifie 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 pendant 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 this cerebral state. This paper proposes a novel method for detecting fatigue from a single electrode, that can be implemented in real-time. The paper first presents a method to determine the most relevant EEG channel to monitor fatigue, using maximum covariance analysis. The second contribution is developing a machine learning method to detect fatigue from this single channel using spectral features and a Long Short-Term Memory (LSTM) deep learning model. Experiments with 12 EEG signals were conducted to discriminate the fatigue stage from the alert stage. Our main finding shows that TP7 was the most relevant channel for monitoring fatigue. Interestingly, this channel is in the left tempo-parietal region where spatial awareness and visual-spatial navigation are shared. It is also related to the faculty of cautiousness. In addition, despite the small dataset, the proposed method yields 75% accuracy for predicting fatigue with a 1.4-second average delay. These promising results provide new insights when developing strategies for monitoring driver fatigue.

