

A Subject-Transfer Framework for Obviating Inter- and Intra-Subject Variability in EEG-Based Drowsiness Detection

Valentin Chiffard¹

¹Affiliation not available

November 8, 2021

1- Introduction

L'article que nous allons étudier est intitulé "A Subject-Transfer Framework for Obviating Inter- and Intra-Subject Variability in EEG-Based Drowsiness Detection" (Wei et al., 2018). Dans le cadre de la détection de la somnolence par un électroencéphalogramme, cet article présente une nouvelle approche d'apprentissage par transfert permettant de « réduire le temps de calibration pour un nouvel utilisateur de 90% (18,00 min à $1,72 \pm 0,36$ min) sans compromettre les performances » (Wei et al., 2018).

Cet article est paru le 01 juillet 2018 dans la revue scientifique *NeuroImage* (volume 174, pages 407-419). Cette revue publiée par *Elsevier Science* est spécialisée dans le domaine de la neuroimagerie. Les contributeurs de l'article étudié sont :

- **Chun-Shu Wei**, doctorant du département de bioingénierie de l'université de Californie San Diego aux États-Unis lors de l'écriture de l'article, actuellement professeur agrégé dans le *Department of computer science* de l'Université nationale Yang Ming Chiao Tung. ([Lien bio](#))
- **Yuan-Pin Lin**, professeur agrégé à l'Institut des Sciences Médicale et Technologique de l'Université nationale Sun Yat-sen à Taïwan. ([Lien bio](#))
- **Yu-Te Wang**, doctorant du département de bioingénierie de l'université de Californie San Diego aux États-Unis lors de l'écriture de l'article, actuellement chercheur dans le domaine des *Brain Computer Interface* chez Microsoft. ([Lien bio](#))
- **Chin-Teng Lin**, professeur agrégé à l'Institut de l'Intelligence Artificielle à l'université de Technologie à Sydney en Australie. ([Lien bio](#))
- **Tzyy-Ping Jung**, professeur agrégé du département de bioingénierie de l'université de Californie San Diego aux États-Unis. ([Lien bio](#))

Dans un premier temps, nous allons présenter le contexte dans lequel l'article s'inscrit. Dans un second temps, nous étudierons les différents travaux réalisés sur le sujet abordé par l'article, puis nous présenterons les contributions de ce dernier. Après avoir expliqué les différentes expériences et les différents résultats obtenus, nous concluons sur cet article.

2- Contexte de l'article

Les BCI (Brain Computer Interface) enregistrent des signaux émis par le cerveau et les « traduits sous forme de message ou de commande pour certaines tâches interactives » (Clerc et al., 2016).

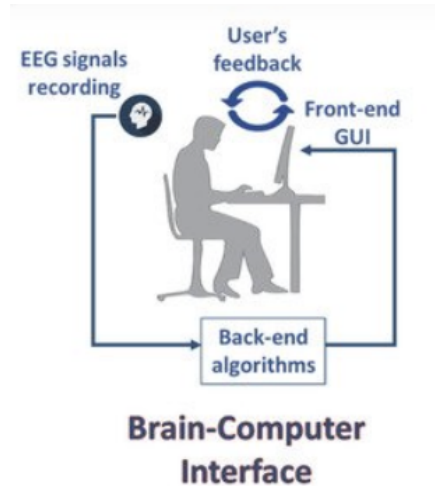


Figure 1: Schéma de fonctionnement d'un BCI (Aricò et al., 2020)

Il est possible par exemple, de faire bouger un curseur d'ordinateur avec des signaux électriques captés par des EEG (Zhu et al., 2005). Les BCI avaient pour publics initiaux les personnes en situation de handicap (comme la quadriplégie) à travers par exemple l'étude de l'utilisation de fauteuil roulant contrôlable par les signaux émis par le cerveau. Récemment, l'utilisation des BCI a été généralisée aux personnes n'étant pas en situation de handicap et à des domaines plus divers comme la détection de la somnolence par EEG non-invasifs (Clerc et al., 2016). L'un des freins à la démocratisation de l'utilisation des BCI est la variabilité présente entre différents sujets (inter-sujet) et la variabilité d'un même sujet (intra-sujet) (Morioka et al., 2015). La variabilité intra-sujet peut être expliquée par les conditions physiques ou mentales qui peuvent changer d'une séance d'EEG à une autre (fatigue, préoccupation etc.). Cette variabilité impose à chaque début de séance un temps de calibration qui est long (18 minutes, pour la détection de la somnolence chez une personne ayant déjà réalisé des séances) et qui est un frein dans l'utilisation des BCI dans la vie de tous les jours (Wei et al., 2018). L'utilisation du machine learning permet au système de se calibrer en fonction de l'utilisateur (Azab et al., n.d.) (apprentissage effectué à partir d'une base de données construite lors d'autres sessions d'EEG). En réduisant ce temps de calibration, l'utilisation des BCI pourrait être démocratisée et appliquée à des domaines quotidiens variés.

3 Positionnement

Les approches traditionnelles pour l'utilisation des BCI nécessitent un entraînement de l'utilisateur extrêmement long (pouvant varier de plusieurs semaines à plusieurs mois). Les nouvelles approches utilisant le machine learning ont permis de réduire ce temps de calibrage à moins d'une heure (Reuderink et al., 2011).

Il existe deux grandes familles d'approches du sujet dans l'utilisation des BCI ayant recours au machine learning :

- L'approche indépendante
- L'approche nécessitant une formation individualisée

L'approche indépendante ne nécessite pas de calibration à chaque nouvelle séance d'EEG. Celle-ci se base sur d'anciennes sessions réalisées par différents utilisateurs afin de permettre une utilisation directe du BCI (Reuderink et al., 2011). Ces types de BCI sont appelés "plug and play". Cependant, cette approche directe implique une perte de performance et ne peut être utilisée pour n'importe quel domaine. L'approche nécessitant

une formation individualisée présente de meilleures performances que l’approche “plug and play” (Wei et al., 2018).

Cette dernière méthode nécessite avant chaque nouvelle session un étalonnage afin de permettre au système de s’adapter aux signaux cérébraux de l’utilisateur à l’instant de la session. Cette approche est celle étudiée dans l’article présenté. Afin de réduire ce temps d’étalonnage tout en gardant un certain niveau de performance, une stratégie consiste à “étendre la taille des données existantes avec les données d’autre sujet [...] en utilisant des techniques de transfert” (Wei et al., 2018). Les techniques de transferts permettent d’utiliser les données pertinentes d’autres utilisateurs afin de compléter et d’améliorer la calibration d’un utilisateur pour une nouvelle session (Lotte, 2015), cette méthode est considérée comme un apprentissage par transfert. “L’apprentissage par transfert est [...] l’amélioration de l’apprentissage dans une nouvelle tâche par le transfert des connaissances d’une tâche connexe qui a déjà été apprise” (*Handbook Of Research On Machine Learning Applications and Trends: Algorithms, Methods and Techniques*, 2009).

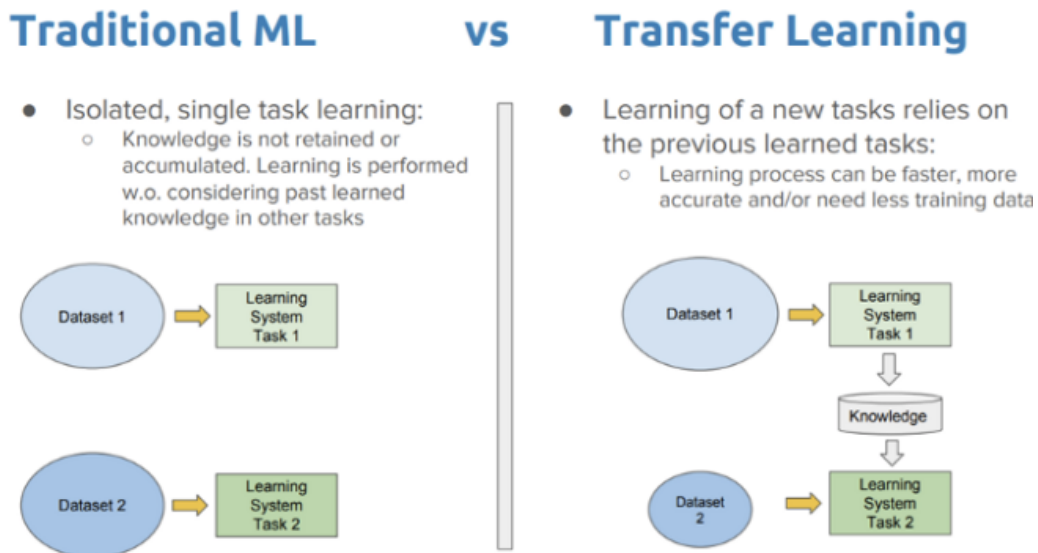


Figure 2: Comparaison du machin learning et du transfer learning (*A Comprehensive Hands-on Guide to Transfer Learning with Real-World Applications in Deep Learning*, Dipanjan (DJ Sarkar))

L’objectif de cette stratégie est de réduire les informations sur l’utilisateur nécessaires à acquérir lors de la calibration d’une session afin d’en réduire son délai.

Ces dernières informations peuvent être collectées en faisant réaliser des tâches spécifiques à l’utilisateur ou en lui faisant réaliser aucune tâche (ou une stimulation passive, comme une tâche d’observation). Dans certains cas d’études (comme celui de la somnolence), il n’est pas évident de faire réaliser des tâches spécifiques (faire rentrer le sujet dans un état de somnolence). C’est pourquoi, certaines études se focalisent sur la calibration par transfert de sujets sans tâches d’étalonnages spécifiques (état de repos)(Yamashita & Sato, 2011).

L’article que nous étudions utilise les techniques de transfert en se basant sur la réalisation d’aucune tâche.

4 Contributions

L'article étudié propose de travailler sur le temps de calibration d'un nouvel utilisateur dans le cadre de l'utilisation d'un BCI pour la détection de la somnolence par EEG . Comme nous avons vu dans la partie 2 (contexte de l'article), les temps de calibration nécessaires pour l'utilisation des BCI sont un réel frein dans leur démocratisation. En réduisant ce temps, les auteurs contribuent à la démocratisation de l'utilisation des BCI et à l'approche "plug and play".

Pour se faire, **les auteurs ont créé un nouveau *subject-transfer framework* pour étalonner le BCI** avec principalement des données appartenant à d'autres sujets (*source session pool*) et une faible quantité de données appartenant au sujet cible. Ce framework ne nécessite pas que l'utilisateur réalise une tâche. **Les données de base alerte** recueillies auprès du sujet cible permettent **d'augmenter la compatibilité** entre le sujet et le *source session pool*. Les données du *source session pool* et les données du sujet cible sont **classées** en fonction de leur comptabilité en **utilisant un modèle linéaire SVR et un MDM** (Multiple Distance Measurement). (Figure 3)

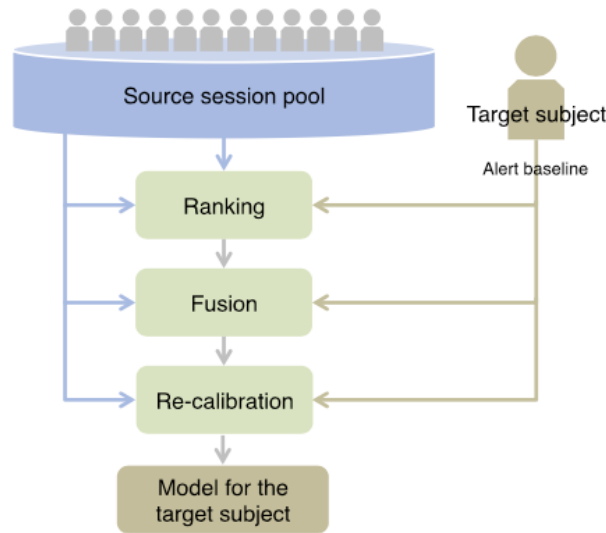


Figure 3: Illustration du *subject transfer framework* proposée par l'article (Wei et al., 2018)

Afin de pouvoir utiliser et valider ce modèle basé sur l'utilisation de données de sujets différents du sujet cible, les auteurs ont **évalué les variabilités inter et intra-sujets** de la dynamique du cerveau dans un état de somnolence. Cela a permis de vérifier une forte compatibilité inter et intra-sujets dans la bande thêta (groupe d'ondes cérébrales). Ce résultat avait déjà été démontré (Jung et al., 1997).

En proposant un modèle de calibration utilisant des données de bases alertes et un classement utilisant un modèle linéaire SVR et un MDM, les auteurs ont réduit le temps de calibration de 90% (18,00 min à $1,72 \pm 0,36$ min) sans réduire la performance du système ($\rho = 0,0910$).

5 Expériences

- a) Évaluation de la variabilité intra et inter-sujet

Afin d'évaluer la variabilité inter et intra-sujets pour valider le principe de fonctionnement du *subject transfer framework*, les auteurs ont fait réaliser à 37 personnes la tâche spécifique de *lane-keeping driving* sous EEG. Le principe de cette tâche est de demander à un conducteur roulant à 100km/h (vitesse constante) en pleine nuit sur un simulateur de conduite de rouler sur une ligne blanche continue marquée au sol (conservation de la trajectoire). Afin de conserver cette trajectoire, l'utilisateur peut uniquement tourner un volant. Le système de simulation est muni d'une plateforme montée sur 6 degrés de liberté et l'utilisateur porte un casque de réalité virtuelle afin d'augmenter la vraisemblance de la tâche. Chaque session dure 1h30 et se déroule après déjeuner pour favoriser la somnolence des conducteurs. Au total, 79 sessions ont été réalisées.

La simulation fait dévier la trajectoire de la voiture de la ligne blanche et le temps de réaction (RT, *Reaction Time*) est mesuré. Le RT représente le temps que l'utilisateur met à exercer une action sur le volant depuis le début de la déviation de la trajectoire (figure 4). Un index normalisé DI (*Drowsiness Index*) a été créé afin de pouvoir traiter cette donnée par la suite:

$DI = \max \left(0, \frac{1 - \exp(-a(\tau - \tau_0))}{1 - \exp(-a(\tau - \tau_0))} \right)$ avec τ la valeur de RT de l'événement étudié, τ_0 la valeur d'alerte RT estimée par la médiane des dix premiers essais réalisés et a une constante mise à $1s^{-1}$.

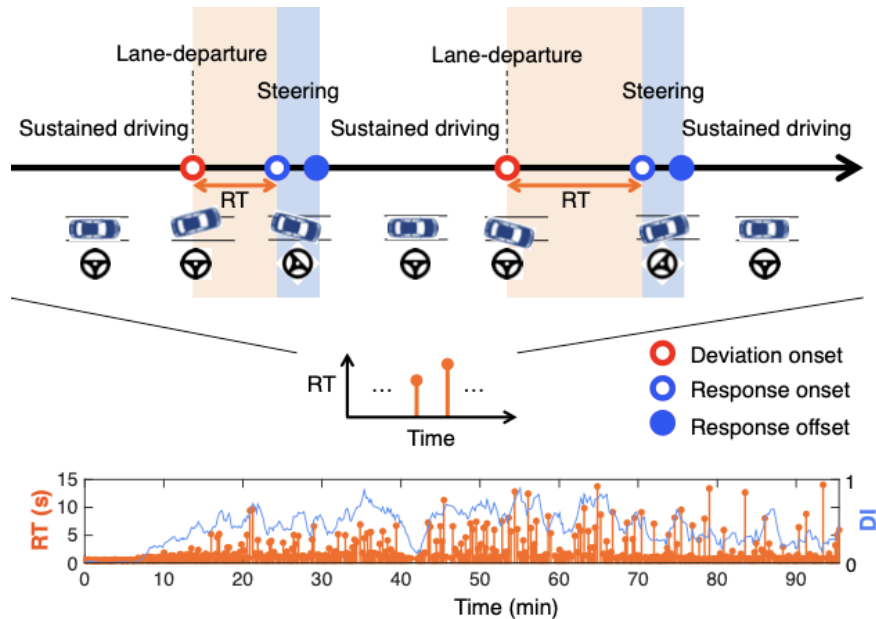


Figure 4: Schéma de l'expérience de *lane-keeping driving* (Wei et al., 2018)

Les résultats obtenus (modification du DI et les bandes de puissances d'EEG (4 bandes de fréquences (alpha, betha, gamma et theta) x 30 channels)) ont permis de créer une *heat map* afin de visualiser les corrélations existantes entre différents sujets et sessions (figure 5). Afin de créer cette *heat map*, les données ont été classées avec la méthode HCA (*Hierarchical Cluster Analysis*). Cette méthode permet de mieux visualiser les liens entre des données sur ce type de graphique.

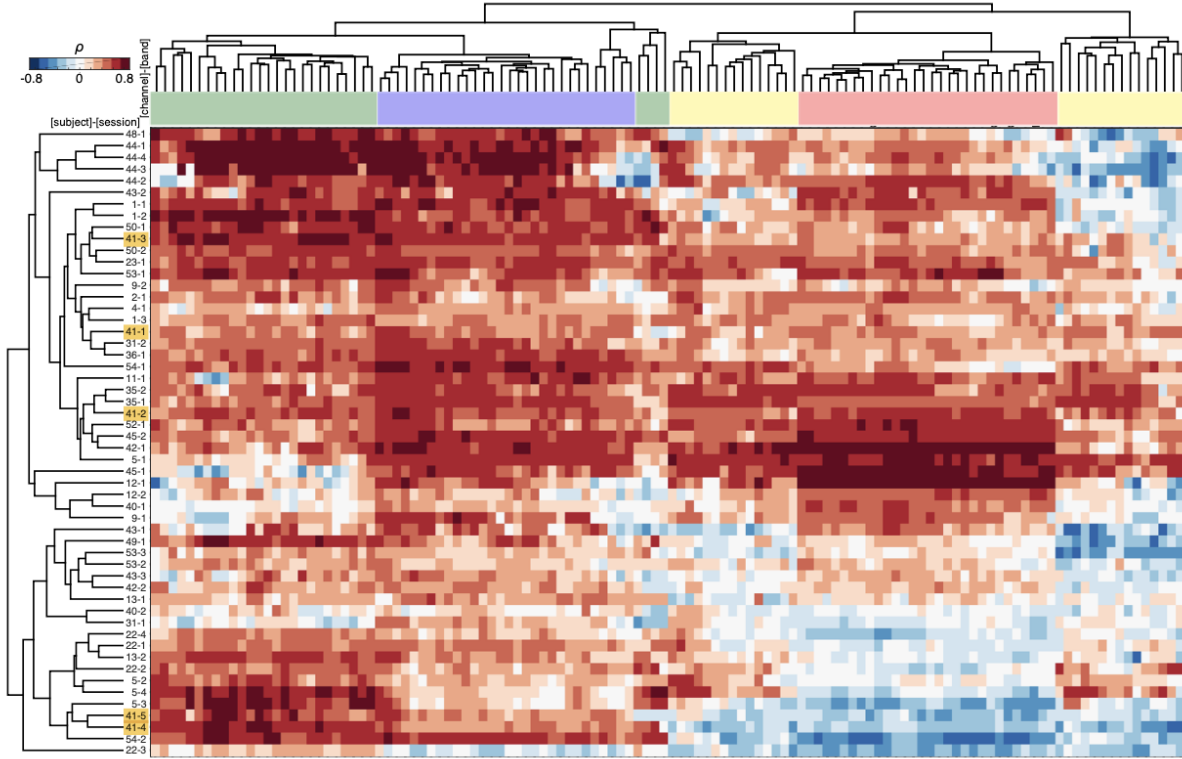


Figure 5: Heat map des sessions (lignes) et des signaux de puissances EEG (colonnes) (Wei et al., 2018)

Les sessions réalisées sont représentées par les lignes et les différentes bandes de puissances d’EEG (Gamma en vert, Theta en bleu, Alpha en rouge et Beta en jaune) sont représentées par les colonnes. Les pixels en rouge représentent une corrélation positive entre les modifications du DI et les bandes de puissance d’EEG et les pixels en bleus une corrélation négative. On peut observer que la bande de puissance ayant la meilleure corrélation entre les sujets est la bande theta (en vert). Ce résultat affirme un lien d’association EEG-DI entre différents sujets et valide le principe de fonctionnement du *subject transfer framework* proposé par les auteurs.

b) Évaluation du *subject transfer framework* proposé

Afin d’évaluer l’efficacité du *subject transfer framework* proposé, 17 essais de calibration ont été réalisés sur des sujets. Chaque session est analysée *offline* avec les deux approches suivantes:

- Une approche basée sur une calibration par *Self Decoding* (SD). Les données utilisées pour effectuer la calibration n’appartiennent qu’au sujet cible. C’est une approche dite “conventionnelle” (Wei et al., 2018).
- Une approche basée sur une calibration par *Subject-Transfer* (ST). Cette approche utilise le *subject transfer framework*.

Pour quantifier la performance de chaque approche, un coefficient de corrélation ρ entre le DI prédit et obtenu est créé. On obtient les résultats suivants:

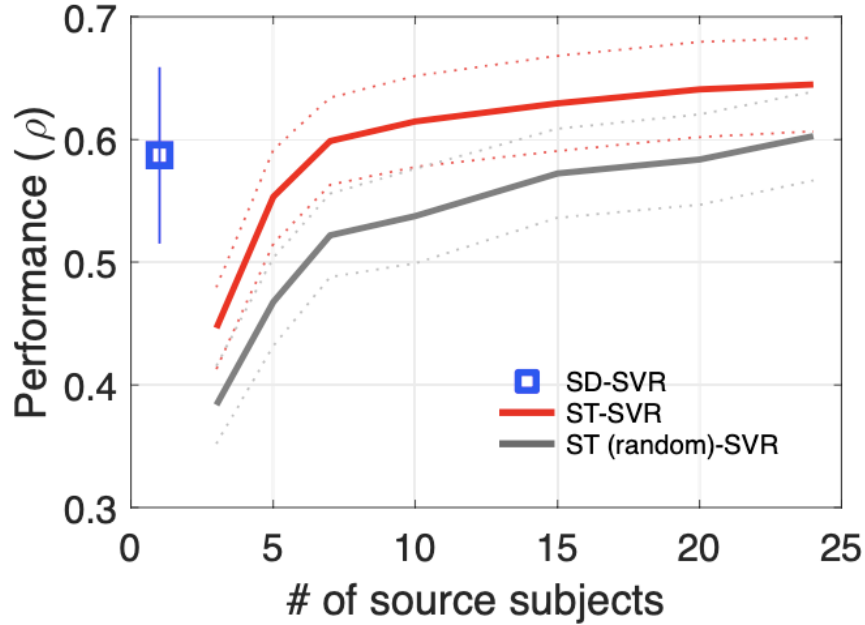


Figure 6: Performance de l’approche ST avec et sans classement (*ranking*) contre l’approche SD en fonction du nombre de sujets présents dans la *source pool*. (Wei et al., 2018)

La figure 6 permet de visualiser que l’approche ST avec un classement (courbe en rouge) est plus performante (+0,05) que l’approche ST (courbe en gris) sans classement. Le classement est donc nécessaire pour augmenter la performance dans l’approche ST. On peut également voir que lorsque la *source pool* est supérieure à 7, la performance de l’approche ST avec classement est supérieure à la performance de l’approche SD. La taille de la *source pool* a donc une influence sur les performances du calibrage proposé.

La performance du *subject transfer framework* est donc validée (supérieur ou égal a la performance de l’approche conventionnelle SD) lorsque la taille du session pool est supérieure ou égale à 7.

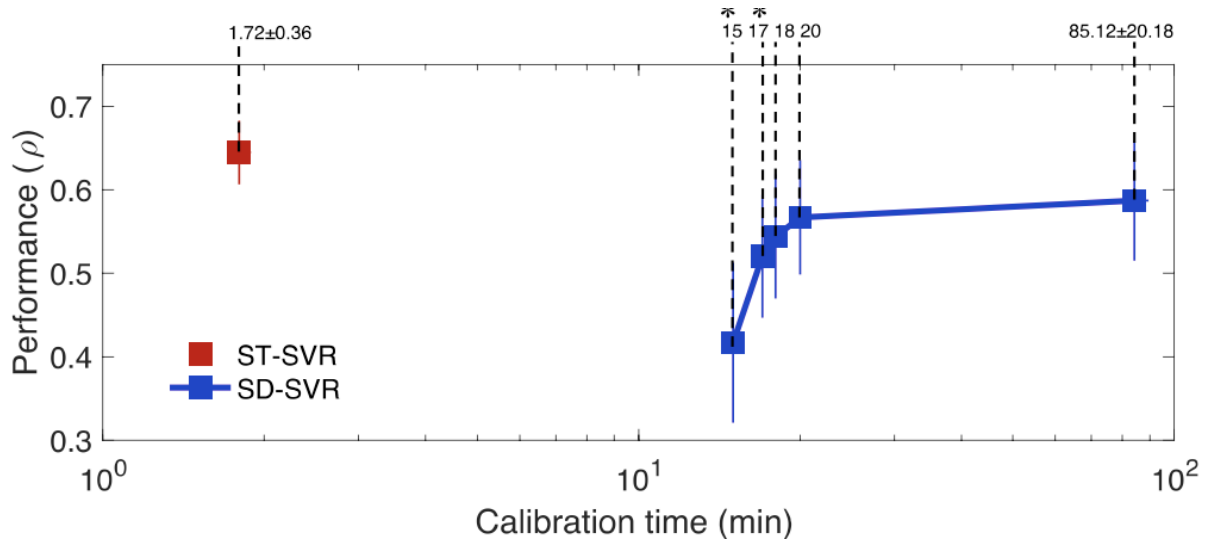


Figure 7: Comparaison du temps de calibration entre l’approche ST (taille de la *source pool* de 17 sujets) et SD en fonction de la performance ρ (Wei et al., 2018)

La figure permet de démontrer que l’approche ST obtient une performance en $1.72 \pm 0,36$ min supérieure à la performance obtenue en 18 min par l’approche SD.

Le temps de calibration du *subject transfer framework* est donc validé (réduction de 90% du temps de calibration par rapport à l’approche conventionnelle SD).

Le *subject transfer framework* proposé par l’article est donc **plus performant** et **plus rapide** dans le cadre d’une calibration pour la détection de la somnolence par EEG que l’approche SD conventionnelle.

6 Conclusions

L’article nous a permis d’identifier que le temps de calibration est l’un des principaux freins dans la démocratisation de l’utilisation des BCI. Pour répondre à cette problématique, les auteurs ont proposé une nouvelle approche de calibration basée sur un apprentissage par transfert dans le cadre de la détection de la somnolence par EEG. Ils ont réduit le temps de calibration d’un utilisateur pour une nouvelle session de 90% (18 min à $1.72 \pm 0,36$ min) sans compromettre la performance de la calibration.

Ce type d’approche pourrait être démocratisé dans d’autres domaines que la somnolence et permettre la démocratisation de l’utilisation des BCI avec une calibration dite “plug and play”.

References

A subject-transfer framework for obviating inter- and intra-subject variability in EEG-based drowsiness detection.. (2018). *Neuroimage*, 174, 407–419.

Brain-Computer Interfaces 1. (2016). John Wiley & Sons Inc. <https://doi.org/10.1002/9781119144977>

- Brain-Computer Interfaces: Toward a Daily Life Employment. (2020). *Brain Sciences*, 10(3), 157. <https://doi.org/10.3390/brainsci10030157>
- Bayesian Method for Continuous Cursor Control in EEG-Based Brain-Computer Interface. (2005). *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference*. <https://doi.org/10.1109/iembs.2005.1616130>
- Learning a common dictionary for subject-transfer decoding with resting calibration.. (2015). *Neuroimage*, 111, 167–178.
- A review on transfer learning approaches in brain-computer interface. In *Signal Processing and Machine Learning for Brain-Machine Interfaces* (pp. 81–101). Institution of Engineering and Technology. https://doi.org/10.1049/pbce114e_ch5
- A subject-independent brain-computer interface based on smoothed second-order baselining. (2011, August). *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. <https://doi.org/10.1109/iembs.2011.6091139>
- A subject-transfer framework for obviating inter- and intra-subject variability in EEG-based drowsiness detection. (2018). *NeuroImage*, 174, 407–419. <https://doi.org/10.1016/j.neuroimage.2018.03.032>
- Signal Processing Approaches to Minimize or Suppress Calibration Time in Oscillatory Activity-Based Brain-Computer Interfaces. (2015). *Proceedings of the IEEE*, 103(6), 871–890. <https://doi.org/10.1109/jproc.2015.2404941>
- (2009). Information Science Reference - Imprint of: IGI Publishing701 E. Chocolate Avenue, Suite 200 HersheyPA.
- Analysis of classifier variability between sessions and subjects for constructing brain machine interface using multiple subject's data. (2011). *Neuroscience Research*, 71, e201. <https://doi.org/10.1016/j.neures.2011.07.868>
- Estimating alertness from the EEG power spectrum. (1997). *IEEE Transactions on Biomedical Engineering*, 44(1), 60–69. <https://doi.org/10.1109/10.553713>