

Mémoire M1 sciences cognitives parcours TECH (Technologies, Ergonomie,
Cognition et Handicap)

2025-2026

Électrophysiologie des plantes - Projet Robot Go West

Stage au Fablab Cohabit du 20/04/2026 au 19/06/2026

université
de BORDEAUX

COH@BIT
fablab

 **vegetalsignals**

Tuteur : Pierre Grangé Praderas

Enseignant référent : Marc-Michel Corsini

Arthur Tétaz

Résumé

Ce stage, réalisé au Fablab Cohabit dans le cadre du Master 1 Sciences cognitives parcours TECH, vise à établir un parallèle entre l'électrophysiologie humaine (*EEG*) et végétale. L'objectif principal était de classer des signaux bioélectriques de plantes en fonction de leur exposition à la lumière, en discriminant les phases de jour et de nuit et en adaptant des méthodes d'apprentissage profond.

Nous avons utilisé un réseau de neurones convolutif (*EEGNet*), initialement conçu pour l'analyse de signaux EEG humains, basé sur l'article de Lawhern et al., 2018. Les données ont été acquises via 8 capteurs placés sur une *Monstera Deliciosa*, enregistrant des signaux à 250 Hz. Après avoir appliqué un filtrage *notch* (50 Hz, $Q=1$) pour atténuer les interférences électriques, les données ont été séparées en ensembles d'entraînement, de validation et de test, et labellisées (« jour » et « nuit »).

L'analyse des variances a révélé des différences significatives entre les coefficients de variation des signaux de jour et de nuit, confirmant une composante biologique liée à la lumière. Le modèle a atteint une précision de 95 % sur les données de validation, mais avec des fluctuations liées au choix des hyperparamètres.

Ce travail constitue une première étape pour la transposition des méthodes EEG à l'électrophysiologie végétale. Cependant, faute de temps, nous n'avons pu tester qu'un nombre limité de combinaisons d'hyperparamètres et un seul type de filtre. Bien que le réseau de neurones désigné au départ pour l'analyse EEG, que nous avons implémenté, serait capable de classer des données électrophysiologiques, il réalise un apprentissage trop erratique pour être généralisable à cause des données complexes.

This internship, conducted at Fablab Cohabit as part of the Master 1 Cognitive sciences (TECH track), aims to establish a parallel between human electrophysiology (EEG) and plant electrophysiology. The primary objective was to classify bioelectrical signals from plants based on their light exposure, discriminating between day and night phases by adapting deep learning methods.

We used a convolutional neural network (*EEGNet*), originally designed for human EEG signal analysis, based on the paper by Lawhern et al., 2018. Data were acquired using 8 sensors placed on a *Monstera Deliciosa*, recording signals at 250 Hz. After applying a notch filter (50 Hz, $Q=1$) to reduce electrical interference, the data were split into training, validation, and test sets, and labeled as "day" and "night."

The analysis of variance revealed significant differences between the coefficients of variation for day and night signals, confirming a biological component related to light. The model achieved 95% accuracy on the validation data, though with fluctuations linked to the choice of hyperparameters.

This work represents a first step toward transposing EEG methods to plant electrophysiology. However, due to time constraints, we were only able to test a limited number of hyperparameter combinations and a single filter type. Although the neural network originally designed for EEG analysis, which we implemented, is capable of classifying electrophysiological data, it exhibits overly erratic learning to be generalizable due to the complexity of the data.

Note sur l'utilisation d'outils d'intelligence artificielle

Je, soussigné Tétaz Arthur, certifie avoir eu recours à des outils d'intelligence artificielle générative (IAG) dans la cadre de la rédaction de ce mémoire.

Le contenu présenté est le résultat de mon travail personnel, de mes lectures, de mon analyse et de mon expérience de stage, avec l'assistance des outils d'IAG suivants :

- Mistral AI et Gemini pour résumer certains articles scientifiques et décider de les lire ou les écarter. Les références présentes en bibliographie ont toutes été lues.

J'atteste avoir exercé un contrôle rigoureux sur les productions générées, en les vérifiant et les corrigeant afin d'en assurer l'exactitude et la cohérence avec mes propos et ma réflexion. Notamment pour les résumés d'articles, une vérification a été faite à chaque résumé pour m'assurer que l'outil utilisé n'inventait pas de sources et se basait uniquement sur l'article donné.

La présente déclaration atteste de mon engagement à utiliser les outils d'IAG de façon responsable, transparente et conforme aux principes d'intégrité scientifique et de rigueur académique.



Sommaire

Résumé.....	2
Note sur l'utilisation d'outils d'intelligence artificielle.....	4
Contexte du stage.....	6
1. Introduction.....	8
2. Méthode.....	17
2.1. Matériel utilisé.....	17
2.1.1. Machine de calcul.....	17
2.1.2. Capteurs.....	17
2.1.3. La plante.....	17
2.2. Entraînement du modèle sur le jeu de données EEG.....	18
2.2.1. Recherche et exploration.....	18
2.2.2. Jeu de données.....	18
2.2.3. Construction du modèle.....	19
2.3. Formatage des fichiers, récupération et traitement du signal.....	20
2.3.1. Acquisition, labellisation et séparation des données.....	20
2.3.2. Format de fichier.....	22
2.3.3. Traitement du signal.....	22
2.4. Entraînement du modèle sur le jeu de données de la plante.....	22
3. Résultats.....	24
3.1. Résultats sur le jeu de données EEG.....	24
3.2. Résultats sur le jeu de données de la plante.....	25
3.2.1. Exploration des signaux bruts et filtrés.....	25
3.2.2. Analyse des variations temporelles.....	27
3.2.3. Analyse statistique des variations.....	28
3.2.4. Évaluation des performances du modèle.....	29
4. Discussion et Conclusion.....	31
4.1. Performance du modèle sur le jeu de données EEG.....	31
4.2. Jeu de données de plantes.....	31
4.2.1. Exploration des données brutes et filtrées.....	31
4.2.2. Visualisation des données brutes sur l'ensemble des données.....	32
4.2.3. Analyse statistique des variations (ANOVA).....	32
4.2.4. Performance du modèle adapté au jeu de données de la plante.....	32
Bibliographie.....	34
Annexe.....	36

Contexte du stage

Dans le cadre de ce stage de Master 1 d'une durée de deux mois, j'ai choisi d'intégrer un Fablab (fabrication laboratory), espace dédié à la conception, à la fabrication et à l'expérimentation collaborative. J'ai découvert le Fablab Cohabit (Creative Open House at Bordeaux Institute of Technology), situé à Gradignan, grâce à Quentin, ancien étudiant de la licence MIASHS, rencontré lors d'une table ronde organisée par l'association Asco'ergo du master. Fondé en 2014 par Frédéric Bos, alors directeur de l'IUT de Bordeaux, Cohabit est une association qui regroupe deux entités complémentaires : le Fablab et le Technoshop. Cette structure a pour vocation de renouveler les pratiques expérimentales en s'appuyant sur une approche pédagogique fondée sur l'apprentissage par l'action « learning by doing ». Elle vise également à accompagner la transition numérique en favorisant les dynamiques collaboratives, le partage des connaissances et l'innovation ouverte.

Le Fablab Cohabit regroupe plusieurs projets, mais celui qui a retenu mon attention est le projet *Robot Go West*. Ce projet consiste à concevoir un robot mobile capable de se déplacer en direction du soleil tout en transportant des plantes. Les signaux électrophysiologiques émis par celles-ci sont acquis puis convertis en commandes destinées aux moteurs du robot, permettant ainsi aux plantes de se rapprocher progressivement de la lumière solaire grâce à ce système de déplacement autonome. Ce projet s'articule autour de plusieurs volets complémentaires. Le premier concerne l'électrophysiologie végétale, incluant l'acquisition des signaux au moyen de capteurs placés sur les plantes ainsi que leur traitement. Le boîtier regroupant les capteurs est nommé CAN, convertisseur analogique-numérique, nous a été offert par l'entreprise VegetalSignals au cours d'un partenariat. Le deuxième porte sur l'exploitation des données recueillies, notamment à travers le développement d'un modèle d'apprentissage profond, *deep learning*, et l'évaluation de ses performances. Enfin, le troisième volet est consacré à la mobilité du robot, comprenant sa conception mécanique et la traduction des signaux biologiques en commandes de pilotage des moteurs. En raison de l'ampleur et de la pluridisciplinarité du projet, les travaux réalisés au cours du stage se sont principalement concentrés sur les deux premiers volets, à savoir l'électrophysiologie des plantes et l'entraînement des modèles de traitement des données. Ce qui a permis d'approfondir les aspects liés à l'acquisition, à l'analyse et à la modélisation des signaux biologiques.

Au début, nous étions deux sur le projet, Jhodi en service civique, diplômé d'un master en Bio-Informatique, et moi-même. Très rapidement, un ingénieur en programmation, Ludovic, s'est joint au projet. Personnellement, je suis resté sur la partie d'apprentissage profond. Mes missions étaient de faire la documentation et de créer un réseau de neurones capable de repérer des patterns distincts sur les représentations des signaux électriques des plantes pour détecter si elles se situent au soleil ou à l'ombre.

1. Introduction

Les sciences cognitives sont un ensemble de disciplines dans lesquelles on retrouve l'informatique, les neurosciences, la linguistique, la psychologie, l'anthropologie et la philosophie. Elles permettent d'étudier les mécanismes de la pensée humaine en passant par leurs descriptions, leurs explications et leurs simulations, en passant par l'étude du comportement humain ou par la mesure de signaux électriques de type EEG (électroencéphalogramme). Dans ce stage, nous cherchons à établir un parallèle entre l'étude de signaux EEG et l'électrophysiologie végétale. Au lieu d'étudier le cerveau humain, qui se trouve au centre des sciences cognitives, nous nous intéressons au fonctionnement des végétaux et leurs processus bio-cellulaires, afin de faire des liens avec les humains via l'étude de signaux électrophysiologique.

Il existe un parallèle entre les signaux renvoyés par une plante et les neurones de mammifère, chez les plantes, ce sont des flux de protons (H^+), d'ions potassiques (K^+) et d'autres anions qui peuvent provoquer des dépolarisations, repolarisations et hyperpolarisations dans la membrane plasmique (Chaparro-Cárdenas et al., 2021). Ce mécanisme est étrangement similaire à ce que nous connaissons des neurones de mammifères, qui sont eux aussi, stimulés par des flux ioniques. Les échanges d'ions à travers la membrane cellulaire et les portes d'activation des canaux à sodium (Na^+) et à potassium sont provoqués par la transmission du potentiel d'action (Figure 1). Ce qui permet la transmission des messages nerveux, autrement appelés influx nerveux. Ces événements font augmenter puis diminuer le potentiel électrique d'une cellule, c'est ce qu'on appelle respectivement la dépolarisation et la repolarisation. Ces variations peuvent être causées par un stress externe ou simplement par la transmission d'un message. Ces signaux électriques sont alors vecteurs d'information quant à l'état physiologique d'un individu (Hodgkin & Huxley, 1952).

Si chez les mammifères les signaux électriques se propagent d'un neurone à un autre via les axones et les dendrites, chez les plantes, ils se propagent via le phloème, qui est un conduit qui fait partie du système vasculaire des plantes avec le xylème. De plus, chez les plantes chlorophylliennes, il est important de noter qu'une partie des signaux provient de la photosynthèse. La photosynthèse est un processus par lequel les organismes photosynthétique, des plantes mais

aussi certains microbes, produisent de la matière organique sous forme de sucre. Ce processus est catalysé en présence de lumière, d'où le terme « photo » dans photosynthèse. Tous les organismes photosynthétiques ne réalisent pas la photosynthèse de la même façon mais ce processus commence toujours par l'absorption de l'énergie lumineuse grâce aux chlorophylles, qui sont des pigments photosynthétiques, présents notamment dans les feuilles des plantes, afin de transformer l'énergie lumineuse ainsi que le dioxyde de carbone (CO_2) et l'eau en matière organique, en sucre et en dioxygène (O_2), comme l'illustre la Figure 2.




Figure 1. Schémas représentant la chaîne ionique au niveau neuronal, à gauche, et au niveau cellulaire végétal, à droite. https://www.researchgate.net/figure/The-natural-ion-channel-on-the-thylakoid-membrane-of-green-plant-leaves-top-and-the_fig2_259353442, https://www.researchgate.net/figure/The-natural-ion-channel-on-the-thylakoid-membrane-of-green-plant-leaves-top-and-the_fig2_259353442

Le but de l'électrophysiologie végétale est de pouvoir faire un diagnostic précis de l'état d'une plante, voir même des prédictions, pour permettre d'apporter une réponse adaptée et spécifique. A terme, l'objectif est de réduire l'usage d'intrant chimique et/ou endiguer la progression de maladies. Plusieurs études, (Chaparro-Cárdenas et al., 2021; Tian et al., 2021; Volkov et al., 2007), démontrent la possibilité d'extraire les signaux électriques de plantes pour observer leurs états de croissance et leurs réponses face à un événement extérieur stressant. D'autres, (Song et al., 2010; Volkov et al., 2019), montrent également que les végétaux communiquent entre eux, via de nombreux mécanismes de communication tels que les composés organiques volatils, les connexions souterraines, etc. Il serait donc intéressant d'analyser les signaux électriques de plantes et les classer en fonction des conditions de cette dernière.

Comme dit précédemment, une partie des signaux qu'on mesure chez la plante provient de la photo synthèse, qui a lieu en journée, mais il est important de noter que la photosynthèse et le cycle circadien d'une plante ne sont pas toujours corrélée. Le rythme biologique chez les plantes est d'environ 24 heures et est contrôlé par des horloges internes, principalement des gènes, qui régulent l'ouverture et la fermeture des stomates, l'activité des pompes ioniques, la synthèse de métabolites et les potentiels électriques membranaires. Ces processus génèrent des signaux électrophysiologiques mesurables tels que des courants électriques dans les tissus vasculaires, via le phloème et le xylème, des variations de potentiel membranaire et également des potentiels d'action dans les cellules végétales, similaires aux neurones (Hubbard & Webb, 2015; Shim et al., 2017).

Le cycle circadien et la photosynthèse interagissent pour moduler les signaux des plantes. Quand le cycle circadien contrôle l'expression des gènes des canaux, la photosynthèse fournit l'énergie pour activer ces canaux dans la journée et diminue la production d'énergie et des flux ioniques lorsque la nuit approche. Le cycle circadien synchronise également la transmission des variations de potentiel dans les feuilles, liées à la photosynthèse, aux racines via le phloème (Dodd et al., 2015).

Nous cherchons donc d'abord à réaliser une preuve de concept qui consiste à démontrer qu'il est possible de discriminer les phases de jour et de nuit d'une plante par analyse de ses signaux électrophysiologiques. Pour cela, une partie importante à expliquer est le traitement du signal. Comme son nom l'indique, le traitement du signal est la discipline qui étudie des techniques de traitement, d'analyse et d'interprétation des signaux. Dans notre cas il s'agit de traiter des signaux électrophysiologiques mais il peut très bien s'agir de traitement du son, traitement d'images ou de vidéos par exemple. Une technique très utilisée pour traiter un signal est la transformée de Fourier. C'est une opération mathématique qui transforme une fonction intégrable en une autre fonction, permettant de décrire le spectre fréquentiel de cette dernière. Dans notre expérience, elle permet de distinguer les amplitudes et les fréquences associées à un signal. Un signal est une grandeur physique porteuse d'informations ; dans des mesures réelles cette information peut être accompagné d'un bruit, une grandeur physique de la même nature que celle du signal, mais qui perturbe l'extraction ou l'exploitation de l'information. Un indicateur intéressant est la symétrie du signal réel après la transformée de Fourier, appelée symétrie hermitienne.




Figure 2. Schéma du processus de la photosynthèse végétale.
<https://www.monanneeaucollege.com/4.SVT.photosynthese.html>

L'outil permettant de faire le lien entre l'étude des signaux électrophysiologiques et leur classification est le réseau de neurones artificiels. Un réseau de neurones artificiels est un ensemble de nœuds interconnectés inspiré de la manière de comment fonctionne le cerveau humain. Cette structure englobe le *deep learning*, apprentissage profond, qui est une technique spécifique du *machine learning*, apprentissage automatique, et qui est également une technique spécifique d'intelligence artificielle (IA), comme l'illustre la Figure 3. L'apprentissage profond est un sous-domaine de ce qu'on appelle communément aujourd'hui l'IA, qui regroupe l'ensemble des systèmes informatiques capables d'effectuer des tâches associées à l'intelligence telles que l'apprentissage, la résolution de problèmes, la perception ou la prise de décision. Il utilise des réseaux de neurones artificiels, composés de plusieurs couches, pour répondre à une problématique précise. La spécificité de l'apprentissage profond est basée sur des réseaux de neurones profonds, contenant plus de couches cachées que les réseaux de neurones traditionnels, permettant d'apprendre des représentations complexes grâce à des couches cachées multiples, illustré dans la Figure 4.

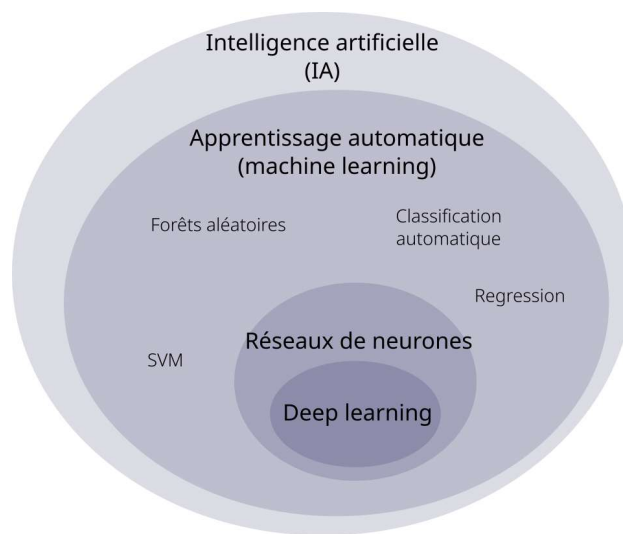


Figure 3. Structure de l'intelligence artificielle englobant l'apprentissage automatique (*machine learning*), les réseaux de neurones et l'apprentissage profond (*deep learning*).

https://fr.wikipedia.org/wiki/Apprentissage_profond#/media/Fichier:Carto_IA_deepLearning.svg




Figure 4. Exemple d'une architecture d'un réseau de neurones profonds appelé réseau de neurones pleinement connectés (*FCNN*), présentant trois couches principales ; les couches d'entrée (*input layer*), les couches cachées ou denses (*hidden layer*) et les couches de sortie (*output layer*).

<https://www.labri.fr/perso/preuter/dl2025/cours1-dl.html>

Chaque neurone artificiel est modélisé selon le modèle de perceptron. Sa sortie est calculé en appliquant une fonction d'activation à la somme des entrées pondérés par les paramètres, qui comportent les poids et son biais. Le terme de « fonction d'activation » vient de l'équivalent biologique « potentiel d'action », et une fois le seuil de stimulation atteint, entraîne une réponse du

neurone. La fonction d'activation est souvent non-linéaire, ce qui permet aux réseaux de neurones d'apprendre des correspondances complexes entre les entrées et les sorties.

En revanche, ce sont les paramètres que le réseau « apprend » pendant la phase d'entraînement. Il existe trois phases afin de séparer les données d'entraînements ; le *training data set*, les données d'entraînement utilisées pour l'entraînement, le *validation data set*, les données de validation utilisées pour ajuster l'architecture et les hyperparamètres, et le *test set*, les données de test pour évaluer la performance. L'intérêt du coupage des données est que les deux premiers, *training* et *validation test*, servent à entraîner et surveiller l'apprentissage tandis que le dernier, *test set*, sert à tester la généralisation. Un exemple concret de séparation est illustré dans la Figure 4. Quant aux hyperparamètres, ce sont des réglages utilisés pour optimiser l'entraînement du réseau, influençant sa performance sans modifier la structure. Parmi eux on retrouve le taux d'apprentissage, ou *learning rate*, le nombre d'époques d'entraînement, ou *epochs*, le nombre de fois que le réseau « voit » les données d'entraînement, la taille du lot, ou *batch size*, le nombre de données d'entrée à partir duquel les poids sont ajustés, le type d'algorithme d'optimisation et le taux de régularisation, comme le *dropout* par exemple.

Pour évaluer la performance d'un modèle de classification, deux mesures sont principalement utilisées : la précision, ou *accuracy*, qui représente la proportion de prédictions correctes parmi toutes les prédictions faites en évaluant l'efficacité globale du modèle sans donner d'indication sur les erreurs spécifiques, et la perte, ou *loss*, qui quantifie l'écart entre les prédictions du modèle et les valeurs réelles, guidant ainsi l'optimisation du modèle. Il est également utile de représenter graphiquement les erreurs lors de l'apprentissage du modèle afin de détecter si ce dernier est en sur-apprentissage, *overfitting*, c'est-à-dire que le modèle apprend trop bien les données d'entraînement et ne se généralise pas très bien aux autres données, ou en sous-apprentissage, *underfitting*, c'est-à-dire que le modèle n'est pas assez complexe pour capturer les motifs dans les données. Le juste milieu est une bonne généralisation et un bon apprentissage, *good fitting*, illustré dans la Figure 5.

Il existe plusieurs architectures de modèle d'apprentissage profond, l'un d'eux est le réseau convolutif (*CNN*) qui est un type de réseau de neurones artificiels dans lequel le motif de connexion entre les neurones est inspiré par le cortex visuel des animaux. Contrairement à un réseau de neurones pleinement connectés (*FCNN*), illustré dans la Figure 3, ici, chaque neurone d'une couche de convolution n'est connecté qu'à un petit groupe de neurones de la couche précédente. On dit

parfois que les réseaux convolutifs apprennent une « hiérarchie de caractéristiques » car les premières couches capturent des caractéristiques simples, comme les bords et les textures d'images, tandis que les couches plus profondes détectent des structures plus complexes, comme des formes et des objets entiers. Pour traiter les données, ces réseaux utilisent un opérateur de convolution. Plus précisément, ils utilisent des filtres (kernels) sur les données d'entrée. Ces filtres sont de petites matrices de poids (de taille 3x3 ou 5x5 par exemple), qui glissent ou se déplacent sur l'image d'entrée. A chaque position, le filtre effectue un produit élément par élément avec la région correspondante de l'image, puis additionne les résultats pour produire un seul nombre en sortie. Ce processus s'appelle convolution.

Il existe plusieurs outils permettant de construire un réseau de neurones artificiels. Dans notre cas, en utilisant le langage informatique Python, plusieurs bibliothèques, ou *libraries*, sont utilisables. Ces bibliothèques sont un ensemble de fonctions, de classes d'objets et de modules liés à un thème spécifique. Elles sont essentielles pour le calcul scientifique, la manipulation de données et leur visualisation. Il existe des bibliothèques dédiées à l'apprentissage automatique, comme Scikit learn, PyTorch ou TensorFlow Kera, qui permettent de créer et d'entraîner des modèles d'intelligence artificielle.

L'entraînement de ce modèle informatique consiste à repérer des *patterns* ou *features*, autrement dit des indices ou des caractéristiques, qui surviennent de façon récurrente dans un jeu de données afin de classer des états d'un système ; dans notre cas, la plante se trouve à l'ombre ou la plante se trouve au soleil. Plusieurs types d'apprentissages peuvent être utilisés en apprentissage automatique, mais il s'agit ici d'un apprentissage supervisé puisque les données importées dans le modèle sont étiquetées.



Figure 4. Exemple de séparation de données d'entraînement. La séparation est choisie en amont et peut ressembler à la suivante : 42,5 % de données d'entraînement, 37,5 % de données de validation et 20 % de données de test. <https://www.cs.toronto.edu/~kriz/cifar.html>




Figure 5. Graphiques représentant les différentes performances d'apprentissage d'un modèle. A gauche se trouve un exemple de sous-apprentissage, *underfitted*, trop simple et linéaire pour expliquer la variance. Au milieu un bon apprentissage, *good fitting*, qui peut comporter certaines erreurs mais généralise bien. A droite un sur-apprentissage, *overfitting*, qui apprend très bien certaines données précises mais n'arrive pas à généraliser. <https://medium.com/swlh/machine-learning-how-to-prevent-overfitting-fdf759cc00a9>

En partant du constat qu'il existe des systèmes automatiques pour la classification de signaux EEG, (Lawhern et al., 2018; Xu et al., 2020), est-il possible d'appliquer des méthodes similaires pour l'électrophysiologie des végétaux ? Pour répondre à cette question, nous nous sommes basés sur un protocole (*pipeline*) d'analyse d'ERPs (*Event-Related Potentials*), qui sont des variations de l'EEG synchrones à un processus spécifique de traitement de l'information, proposé par Lawhern et al., 2018, pour créer un réseau convolutif. Ensuite, nous expliquerons nos choix quant aux hyperparamètres du modèle ainsi que la pertinence de la performance de ce dernier. Enfin, une partie le traitement et la visualisation des signaux électriques renvoyés par les végétaux.

Le choix de l'architecture EEGNet (Lawhern et al., 2018) s'explique par sa compacité et sa capacité à extraire des caractéristiques temporels et spatiaux, qui sont essentiels pour analyser des signaux électrophysiologiques qu'ils soient humains ou végétaux. Contrairement à des modèles plus lourds (comme *DeepConvNet* par exemple) , EEGNet utilise des convolutions séparables pour réduire le nombre de paramètres tout en captant des motifs locaux qui nous intéresse, comme les variations d'amplitude liées à la lumière.

2. Méthode

Pour adapter les méthodes de traitement du signal EEG (Lawhern et al., 2018) à notre contexte végétal, la méthode est séparée en plusieurs phases, dont certaines ont été réalisées en parallèle et souvent à plusieurs. La première décrit la construction du modèle et l'optimisation des hyperparamètres à partir du jeu de données EEG. La deuxième consiste en la récupération, le traitement des signaux de la plante ainsi que labelliser les données pour former un jeu de données de la plante. La troisième réside dans l'entraînement du modèle sur le jeu de données de la plante. Chaque étape a été conçue pour mimer les protocoles utilisés en neurosciences cognitives.

2.1. Matériel utilisé

2.1.1. Machine de calcul

- Acer Nitro 5 avec carte graphique NVIDIA GeForce GTX 1650, 4 Go VRAM
- Dell Precision avec carte graphique Quadro P4200, 8 Go VRAM

2.1.2. Capteurs

Le boîtier de capteurs VegetalSignals est capable de mesurer des variations de voltage, des différences de potentiels entre une électrode positive et une électrode négative, de l'ordre de 25 nV à une fréquence de 250 Hz. Il est constitué de huit ports positifs et huit ports négatifs. Ce qui fait un total de 16 électrodes. Ces électrodes sont issues du milieu hospitalier et leur longueur est de 2,5 centimètres. Elles sont regroupées par paire et chaque paire est numérotée de 1 à 8. Le tout enregistre les signaux directement sur une carte SD ou via une antenne ou bien via USB en TX-RX, un protocole d'envoi et de réception de données.

2.1.3. La plante

La plante sur laquelle nous avons récolté les données est une *Monstera Deliciosa*, ou faux philodendron, appartenant à la famille des Aracées, *Araceae*. Étant l'unique plante présente au Fablab, nous sommes conscients que ce n'est pas la plante la plus simple à étudier. La plante est disposée dans deux pots, orientée plein sud au premier étage du bâtiment du Fablab.

2.2. Entraînement du modèle sur le jeu de données EEG

2.2.1. Recherche et exploration

Nous nous sommes basés sur un code sur *Github* (Hof, 2024) qui reprenait le même code de l'article de Lawhern et al., 2018, mais en utilisant la bibliothèque PyTorch. Ce qui nous convenait tout à fait notamment car elle est plus souvent utilisée dans le monde de la recherche, mais aussi de par son aspect accessible à tous, dit en *open source*, le débogage automatique intégré à la librairie et sa performance basée sur des réseaux de neurones.

2.2.2. Jeu de données

Le code sur *Github* charge des données aléatoires pour entraîner le modèle. Pour voir un jeu de concret, nous avons décidé d'entraîner le modèle sur un jeu de données EEG (Nguyen, 2025), pris sur la plateforme de données *Kaggle* et inspiré par l'article Andrzejak et al., 2001. C'est le jeu de données EEG de Bonn, reconnu dans le domaine du traitement des signaux biomédicaux et de l'apprentissage automatique. Il est spécialement conçu pour la recherche sur la détection de l'épilepsie et l'analyse des signaux EEG. Il contient des enregistrements EEG provenant à la fois de sujets sains et de patients épileptiques, ce qui le rend adapté à des tâches telles que la détection des crises et la classification des états d'activité cérébrale. Le jeu de données est structuré en cinq dossiers distincts :

- A et B : respectivement les mesures yeux ouverts et yeux fermés pour des individus neurotypiques
- C et D : respectivement les mesures des zones épileptogènes pendant une période sans crise et prélevées dans l'hippocampe de l'hémisphère opposé chez les patients épileptiques
- E : mesures d'une crise épileptique chez les patients épileptiques.

Chaque dossier comprend 100 segments EEG monocanal, pour un total de 500 segments. Chaque segment représente 23,6 secondes de données EEG, échantillonnées à une fréquence de

173,61 Hz, ce qui donne 4 096 points de données par segment. Les données sont stockées au format ASCII sous forme de fichiers texte.

Pour évaluer les performances du modèle, nous avons donc choisi de séparer les données de la façon suivante : 80 % de données d'entraînements, 10 % de données de validation et 10 % de données de test. Ce qui nous donne donc, pour chaque dossier 80 fichiers de données d'entraînements, 10 fichiers de données de validation et 10 fichiers de données de test.

2.2.3. Construction du modèle

L'architecture du modèle EEGNet (Lawhern et al., 2018), qui est un réseau de neurones convolutifs compact et qui s'articule autour de blocs convolutifs optimisés, est conçue spécifiquement pour les interfaces cerveau-ordinateur (*BCI*) et le but est qu'elle soit capable de s'adapter à différents types de signaux EEG, tout en étant la plus compacte possible. Un réseau convolutif, aussi appelé ConvNet, est particulièrement performant car il est capable d'apprendre des caractéristiques spatiales et locales de manière très efficace.

Son architecture s'articule autour d'un empilement de couches spécialisées qui miment la hiérarchie du système visuel. en se basant sur la Figure 6, on a en premier, la couche de convolution 2D (*Conv2D*), qui applique des filtres temporels pour extraire des bandes de fréquences spécifiques. Juste après on trouve la couche de convolution en profondeur (*DepthwiseConv2D*) qui applique un filtre spatial à chaque filtre temporel. Vient ensuite la couche de convolution séparable (*SeparableConv2D*), qui combine la couche en profondeur et une couche de convolution ponctuelle (*PointwiseConv2D*) pour fusionner les caractéristiques, ou *features*, de manière optimale. Son principal avantage est de réduire le nombre de paramètres. Dans ces deux couches de convolution en profondeur et séparable se trouvent les couches de normalisation (*BatchNorm*) qui normalise les activations pour stabiliser l'entraînement et accélérer la convergence, d'activation (*Activation*) qui introduit une activation *ELU*, qui permet d'éviter le problème des neurones qui ne seraient pas activés, de pooling (*AveragePool2D*) qui réduit la dimension temporelle et la taille des tenseurs, et de dropout (*Dropout*) qui désactive aléatoirement des neurones afin de forcer le réseau à apprendre des caractéristiques robustes et généralisables. En dernier, la couche de classification (*Dense* et *Softmax*) qui regroupe les caractéristiques extraits pour prendre une prédiction finale. La spécificité

de ce modèle est qu'il ne contient pas de couche dense intermédiaire, contrairement à DeepConvNet par exemple, ce qui réduit encore plus le nombre de paramètres.

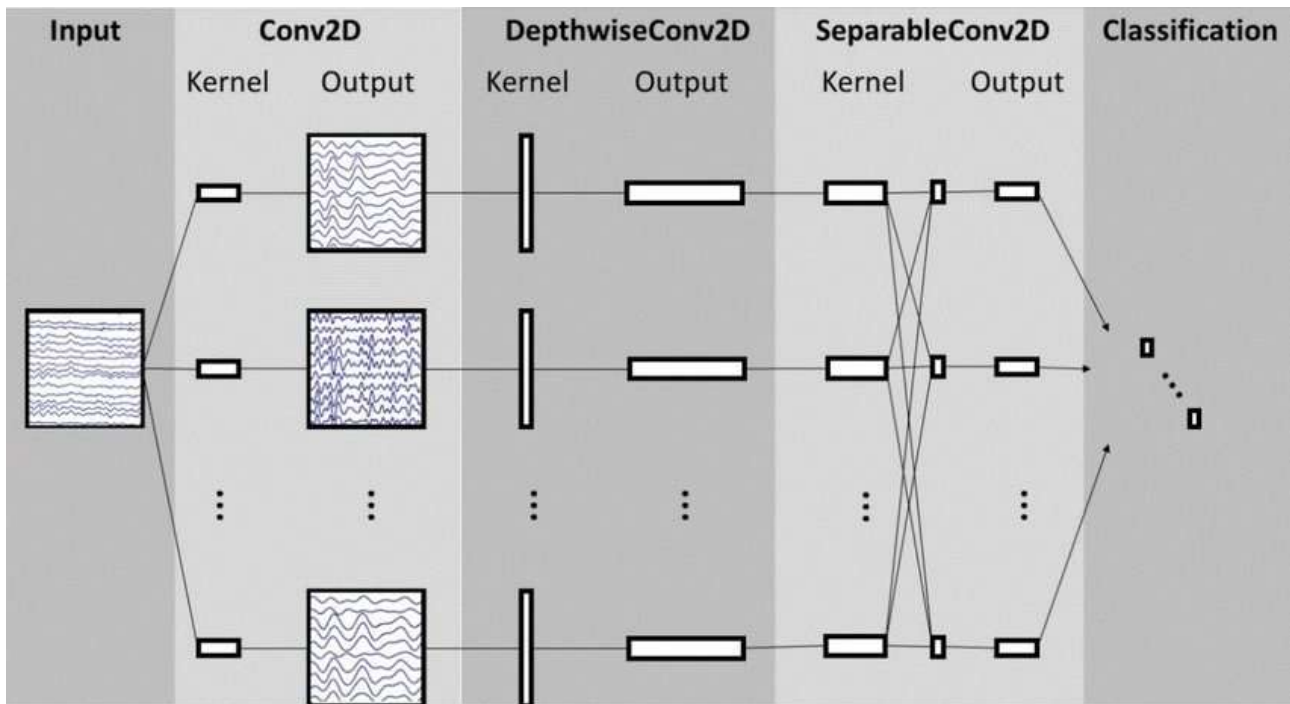


Figure 6. Architecture du réseau convolutif compact de l'article de Lawhern et al., 2018. Avec la couche d'entrée (*input*), de convolution (*Conv2D*), de convolution en profondeur (*DepthwiseConv2D*), de convolution séparable (*SeparableConv2D*) et la couche de classification (*Dense et Softmax*). (Lawhern et al., 2018)

2.3. Formatage des fichiers, récupération et traitement du signal

2.3.1. Acquisition, labellisation et séparation des données

Nous avons opté pour une acquisition directement dans une carte SD car nous manquions de documentation sur le fonctionnement des capteurs et comment communiquer en USB ou à distance. Le boîtier des capteurs est alimenté par quatre piles 2A de 5 volts. Les capteurs ont été plantés entre 3 à 5 millimètres du phloème à différent endroits, illustré dans la Figure 7 et le Tableau 1. Il est important de noter que les 20 premières mesures représentent la réaction de la plante à la blessure infligée par l'implantation de l'électrode dans le phloème. De fait, les mesures ne sont exploitables que 20 minutes après la pose des capteurs.

Lors de notre premier enregistrement, le 7 mai 2026 à 16h23, les piles se sont vidées au bout de 45 heures. Ce premier jeu de données est constitué de 45 940 échantillons de 512 mesures, soit environ 2 secondes d'enregistrement, répartis entre le jour et la nuit. Pour résoudre le problème de la batterie des piles, nous avons donc décidé de brancher le capteur sur secteur, en modifiant nous-mêmes le câble d'alimentation du capteur. Lors du deuxième enregistrement, le 13 mai 2026 à 17h20, 122 heures d'enregistrements ont été récoltées, ce qui correspond à 289 942 échantillons de 512 mesures. Nous avons donc un premier jeu de données correspondant aux enregistrements du 7 mai 2026 et un deuxième jeu de données correspondant aux enregistrements du 13 mai 2026.

Une fois les données récoltées, nous les avons séparées en deux répertoires dans chaque dossier d'entraînement, de validation et de test, un premier « *day* », pour le jour, et un second « *night* », pour la nuit. Les données n'étant pas horodatées, nous nous sommes basé sur la date de début et de fin d'enregistrement, ainsi que les heures de levé et de couché du soleil dans cette période pour séparer les données.




Figure 7. A gauche se trouve un schéma de l'anatomie de la plante Monstera Deliciosa, avec les nœuds (node), la tige (stem), les racines aériennes (aerial roots), les pétioles (petioles) et les feuilles (leaves). A droite, une photo de notre installation de la plante ainsi que la position des capteurs.
https://thebalconygarden.co/blogs/news/propagate-monstera-deliciosa-guide?srltid=AfmBOooW5kHF6vpI0XJDjXeDGzZYMzf5Wkjev_tztgrsm7gSoz_cZIIIn

Numéro	1	2	3	4	5	6	7	8
--------	---	---	---	---	---	---	---	---

de
capteurs

Position du capteur sur la plante	Tige à la base de la plante	Sol	Tige	Pétiole proche de la feuille	Pétiole proche de la feuille	Tige proche du pétiole	Pétiole proche de la feuille	Sol
--	-----------------------------------	-----	------	------------------------------------	------------------------------------	------------------------------	------------------------------------	-----

Tableau 1. Tableau regroupant la position des capteurs sur la plante, ainsi que les numéros des capteurs.

2.3.2. Format de fichier

Après avoir séparé les données brutes, et y avoir appliqué un parseur (un programme utilisé pour analyser une chaîne de caractères et la convertir en une structure de données interprétables) puis nous avons converti les fichiers en *numpy* (.npz), format de fichier binaire natif de NumPy pour stocker un seul tableau numpy.

2.3.3. Traitement du signal

Chaque échantillon de données passe par une étape de filtrage car l'étude des données brutes a montré la présence de nombreux artefacts (Figures 9 à 12). Un filtre *notch* a été appliqué sur les signaux afin de supprimer la fréquence du réseau électrique européen, qui est de 50 Hz, sans affecter les autres fréquences. Dans notre cas, ce filtre supprime la fréquence des 50 Hz avec une largeur de 1 Hz. La largeur de la bande atténuée est le facteur de qualité, noté Q.

2.4. Entraînement du modèle sur le jeu de données de la plante

L'entraînement s'est fait sur les deux jeux de données. En amont, nous avons tester plusieurs combinaisons d'hyperparamètres, comme le *batch size* et le *dropout rate*, sur le jeu de données du 7 mai. Ces résultats préliminaires ont montré qu'un *batch size* élevé (entre 160 et 360) et un *dropout rate* de 0.5, c'est à dire que 50 % des neurones sont désactivés, donnaient un meilleur apprentissage (Figure 16 en annexe).

3. Résultats

Dans un premier temps, pour valider l'architecture de notre modèle, nous l'avons entraîné sur un jeu de données EEG. Une fois fait, nous l'avons testé puis adapté au jeu de données issu de la plante.

3.1. Résultats sur le jeu de données EEG

Les résultats montrent un apprentissage relativement efficace, avec une perte de validation inférieure à 1 et une précision de validation d'environ 90 %. Cependant, on remarque que la validation est plus haute que l'entraînement pour la perte et la précision (Figure 8) alors qu'on aurait pu s'attendre à l'inverse. Ces résultats semblent suggérer que le jeu de données de validation est plus « simple » que le jeu d'entraînement.




Figure 8. Représentations graphiques de l'évolution de la performance du modèle sur les le jeu de données EEG. A gauche se trouve l'évolution de la perte en fonction des époques et à droite l'évolution de la précision en fonction des époques.

3.2. Résultats sur le jeu de données de la plante

3.2.1. Exploration des signaux bruts et filtrés

Les figures 9 à 12 montre une comparaison directe entre les signaux bruts et les signaux filtrés sur deux échantillons en phase de jour et en phase de nuit. En premier lieu, on remarque, pour le tension des signaux bruts, que le capteur 8 se démarque des autres avec une amplitude négative autour de $-1,5 \cdot 10^6$ nanovolts contre $0,5 \cdot 10^6$ nanovolts en moyenne pour les autres capteurs.

Le signal brut, de jour comme de nuit (respectivement la Figure 9 et la Figure 11), montre des pics de fréquence vers 50 Hz et 150 Hz, typiques des interférences électriques. Après application du filtre, les figures 10 et 12 révèlent que le pic à 150 Hz a été supprimé, tandis que le pic à 50 Hz persiste, indiquant que le filtre n'a pas ciblé correctement cette fréquence.

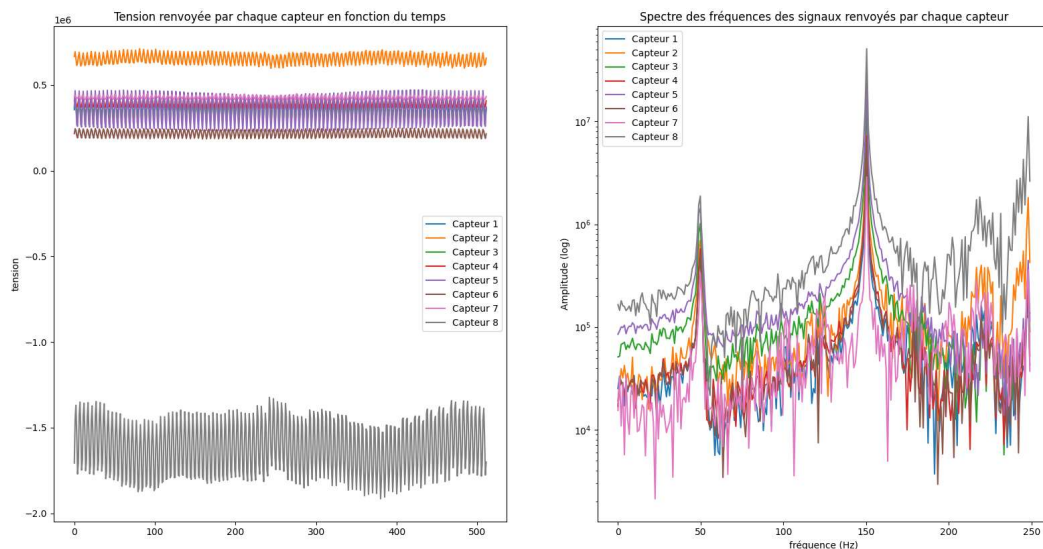


Figure 9. Visualisation graphique des données brutes durant la journée du 7 mai 2026. A gauche se trouve le signal brut, l'amplitude en fonction du temps, et à droite sa transformée de Fourier, l'amplitude en fonction des fréquences.




Figure 10. Visualisation graphique des données filtrées durant la journée du 7 mai 2026. A gauche se trouve le signal brut, l'amplitude en fonction du temps, et à droite sa transformée de Fourier, l'amplitude en fonction des fréquences.

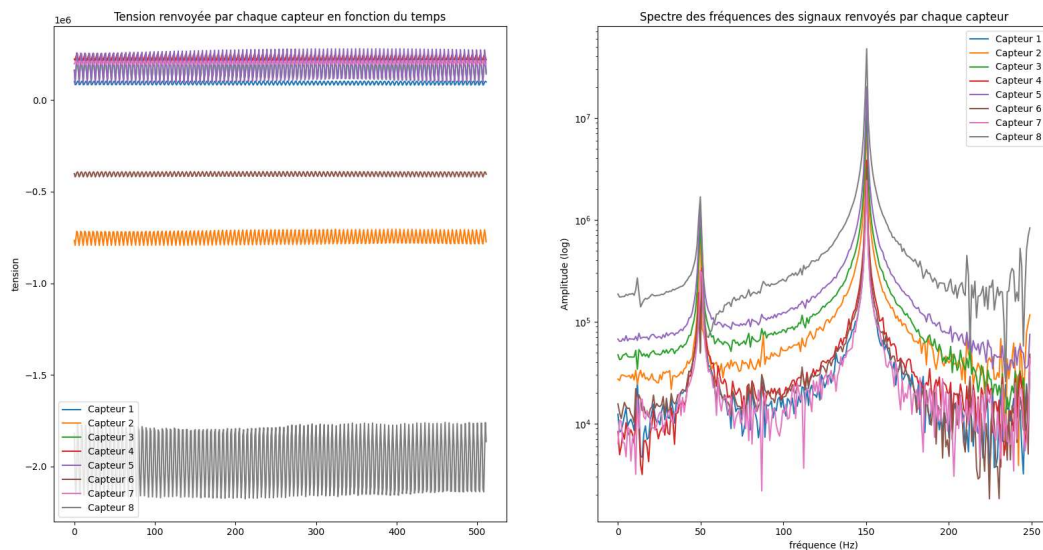


Figure 11. Visualisation graphique des données brutes durant la nuit du 7 mai 2026. A gauche se trouve le signal brut, l'amplitude en fonction du temps, et à droite sa transformée de Fourier, l'amplitude en fonction des fréquences.




Figure 12. Visualisation graphique des données filtrées durant la nuit du 7 mai 2026. A gauche se trouve le signal brut, l'amplitude en fonction du temps, et à droite sa transformée de Fourier, l'amplitude en fonction des fréquences.

3.2.2. Analyse des variations temporelles

La Figure 13 montre l'évolution temporelle des amplitudes de tous les deux jeux de données, du 7 et 13 mai 2026, sur l'ensemble des capteurs, couvrant 167 heures d'enregistrements. Un trait rouge sépare les deux jeux de données. Les signaux du deuxième jeu de données, du 13 mai, semblent présenter des variations périodiques d'amplitude, potentiellement liées à des cycles biologiques ou à des artefacts environnementaux.

Cependant, les signaux enregistrés lors du premier jeu de données semblent varier de façon plus importante. Une cause possible peut être les piles utilisées lors de ces enregistrements ou un rémanent du stress induit par les aiguilles.

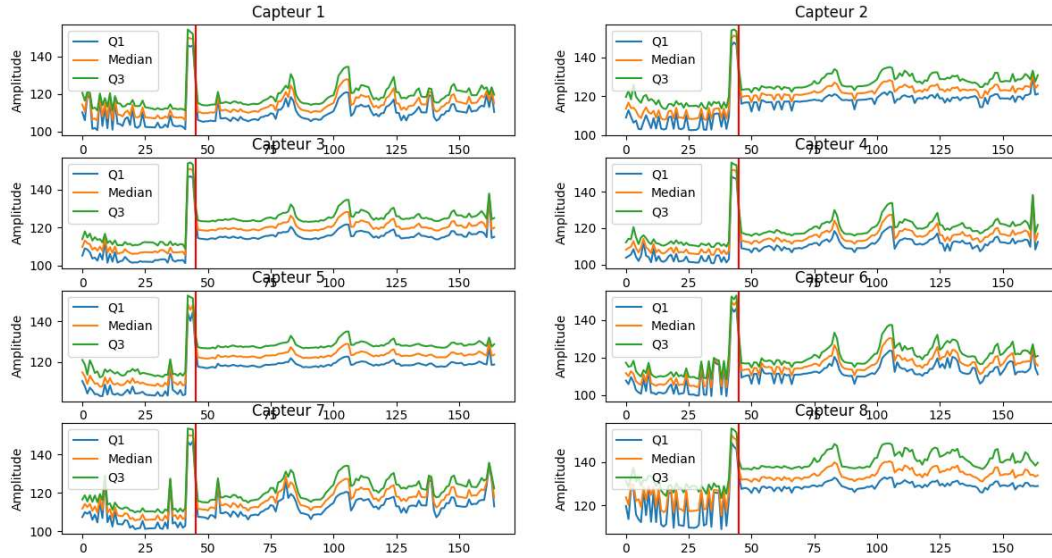


Figure 13. Visualisation graphique de l'évolution temporelle des amplitudes des données brutes complètes par capteur, soit environ 167 heures d'enregistrements. Le trait vertical rouge présent à 44 heures représente la démarcation entre les données du 7 mai 2026, de 45 heures, et les données du 13 mai 2026, de 122 heures.

3.2.3. Analyse statistique des variations

Pour quantifier les différences entre les classes « jour » et « nuit », nous avons calculé le coefficient de variation (CV) en valeur absolue pour chaque enregistrement de chaque capteur, puis effectué une analyse des variances (*ANOVA*) sur les données brutes et filtrées. La Figure 14 montre, d'une part, qu'il existe une différence de variation entre les capteurs et, d'autre part, que le filtrage a eut pour effet de réduire l'amplitude globale des signaux, passant du maximum de 10^3 à 10^2 .




Figure 14. Coefficient de variation (logarithmique) des signaux électrophysiologiques bruts par capteur, comparé entre les classes « jour » et « nuit » (*ANOVA*). A gauche se trouvent les données brutes et à droite les données filtrées.

3.2.4. Évaluation des performances du modèle

L'entraînement a été fait sur 100 époques avec comme hyperparamètres différents *batch size* (360, 960, 1280 et 1600) et un *dropout rate* fixe de 0.5. La Figure 15 montre des apprentissages erratiques et un effet du *batch size* peu significatif à priori. A 360 batch, on observe un sur-apprentissage au bout de 80 époques environ. Pour le reste, nous observons une précision de validation oscillant entre 80 et 95 %.

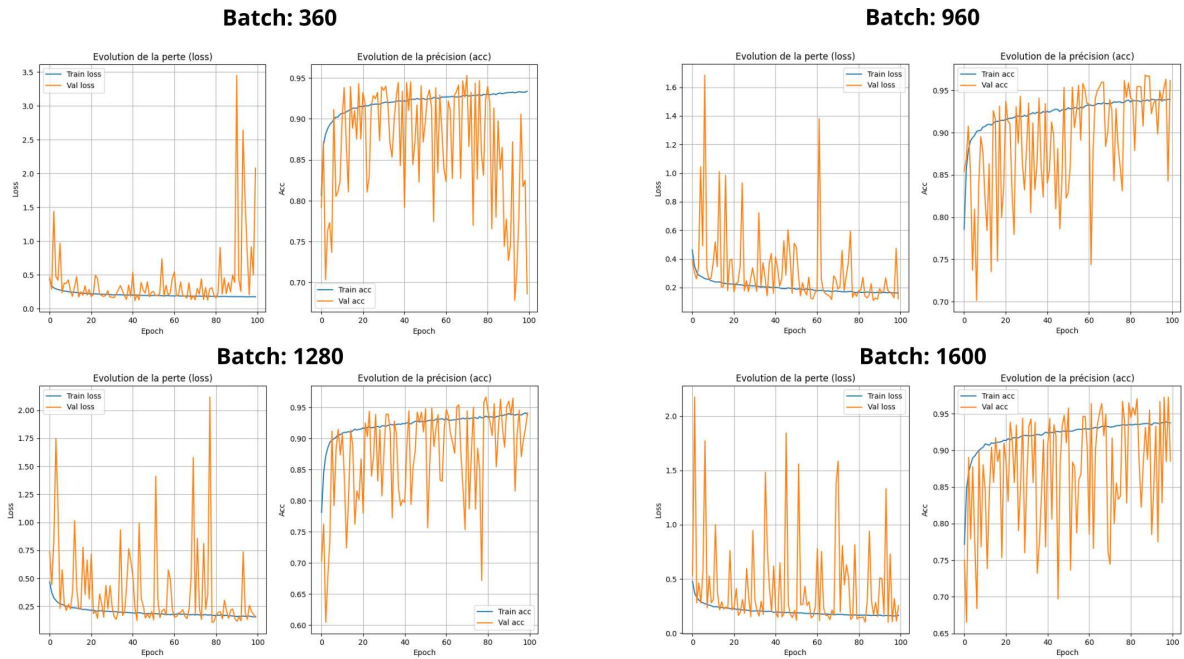


Figure 15. Graphiques représentant l'évaluation de la performance de l'apprentissage du modèle selon différents *batch size* et un *dropout rate* de 0.5. Pour chaque paire de graphe, à gauche est représenté l'évolution de la perte en fonction du nombre d'époques, et à droite l'évolution de la précision en fonction du nombre d'époques.

4. Discussion et Conclusion

Notre travail avait pour objectif d'établir un parallèle entre l'électrophysiologie humaine, basée sur des signaux EEG, et végétale, en adaptant des méthodes de traitement du signal et de classification par apprentissage profond pour distinguer des états physiologiques (jour/nuit) chez une plante. Les résultats obtenus permettent de valider partiellement cette approche transdisciplinaire, tout en soulevant des questions fondamentales sur les mécanismes sous-jacents aux signaux végétaux.

4.1. Performance du modèle sur le jeu de données EEG

Sur le jeu de données EEG (Andrzejak et al., 2001), la performance du modèle semble relativement bonne (Figure 8). Cependant, les données de validation sont mieux apprises que les données d'entraînement, suggérant une mauvaise généralisation probablement dû à la faible taille du jeu de données.

4.2. Jeu de données de plantes

4.2.1. Exploration des données brutes et filtrées

L'amplitude et le signe du signal renvoyé par le capteur 8, pourraient provenir d'une mauvaise implantation du capteur dans la plante. Mais du fait de sa valeur absolue qui reste différente de la moyenne des autres capteurs (1.5 au lieu de 0.5 pour la journée et 2 au lieu de 0 pour la nuit), nous penchons plus sur l'idée d'une réelle différence entre les signaux renvoyés entre les deux pots (Figure 7) car le capteur 2 se trouve également dans la terre. Contrairement à nos attentes, le filtre *notch* n'a pas supprimé le pic présent à 50 Hz mais a enlevé celui présent à 150 Hz. Plusieurs hypothèses peuvent expliquer ce phénomène. La plus probable, serait que la qualité (Q) du filtre n'est pas la bonne. D'autres tests seraient à prévoir en diminuant et en augmentant la qualité pour voir l'incidence sur le pic à 50 Hz. La deuxième serait que le pic à 50 Hz pourrait correspondre à l'activité métabolique de la plante, comme l'ont montré Volkov et al., 2007, certaines plantes génèrent des signaux électriques périodiques en réponse à des stimuli externes.

4.2.2. Visualisation des données brutes sur l'ensemble des données

Les variations plus importantes observées sur le premier jeu de données peuvent venir du stress lié à l'implantation des capteurs dans la plante (Figure 17 et 18 en annexe). Une autre source peut être l'alimentation des capteurs via les piles et non via secteur, qui ont des variations différentes sur les signaux renvoyés par la plante. En effet, le chargeur secteur que nous avons utilisé est facteur de bruit. Le fait d'avoir observé que la plante semble montrer des cycles périodiques (Figure 13) met en évidence une activité électrophysiologique qui peut ressembler à celle de signaux EEG. En neurosciences, les ERPs sont utilisés pour étudier les réponses cérébrales à des stimuli (Lawhern et al., 2018). De la même manière, nos résultats suggèrent que les variations d'amplitude jour/nuit chez la *Monstera Deliciosa* pourraient refléter des réponses physiologiques à des stimuli environnementaux.

4.2.3. Analyse statistique des variations (ANOVA)

Pour les données brutes, après une transformation logarithmique, l'ANOVA révèle qu'il existe une différence entre les coefficients de variation entre les phases de jour et de nuit ($p < 2.2^{16}$), illustré dans les données brutes de la Figure 14 et le Tableau 2 (en annexe). Cette différence est tout aussi significative après filtration ($p < 2.2^{16}$), illustré dans les données filtrées de la Figure 14 et le Tableau 3. Mais avec une moyenne des carrés plus élevée (32 contre 1220).

Les différences significatives entre les coefficients de variation de jour et de nuit, avant et après filtrage, confirment que les variations d'amplitude contiennent bien une composante biologique liée à l'exposition à la lumière et que le filtrage a augmenté la variance du jeu de données ($Mean Sq = 1220.3$ pour les données filtrées contre 32 pour les données brutes), suggérant que les hautes fréquences, supérieures à 50 Hz, pourraient masquer des motifs discriminants.

4.2.4. Performance du modèle adapté au jeu de données de la plante

Les performances sont trop erratiques pour conclure sur une bonne généralisation du modèle. Il serait intéressant à l'avenir de faire plus de tests en modifiant les hyperparamètres, même si un nombre élevé de *batch* semble avoir de meilleurs résultats (Figure 16 en annexe).

Pour conclure, les signaux électrophysiologiques de la *Monstera Deliciosa* et d'EEG humain présentent des similarités de variations périodiques d'amplitudes en fonction d'état physiologiques. Dans notre expérience, nous avons implémenté un réseau convolutif compact entraîné sur un jeu de donnée EEG qui a fourni des performances satisfaisantes mais non généralisables du fait de la taille du jeu de données, contenant seulement 500 échantillons. Nous avons, par la suite, récolté des enregistrements de données électrophysiologiques sur la plante via des capteurs de l'entreprise VegetalSignals et constitué un jeu de données de 289 940 échantillons, discriminé entre jour et nuit. L'analyse statistique du jeu de donnée révèle :

- une périodicité et une hétérogénéité des signaux électriques (Figure 13)
- la présence d'artefacts à 50Hz et 150 Hz (Figure 9 à 12)
- une différence en terme de variations d'amplitude entre jour et nuit (*ANOVA*, $p < 2.2^{16}$) (Figure 14).

Fort de ces observations, nous avons implémenté un filtre *notch* à 50 Hz et un facteur de qualité de 1. Le filtre a permis d'enlever le bruit du signal et d'appuyer les différences observées entre les deux phases (jour et nuit). Malgré ces résultats, le réseau de neurones, adapté au nouveau jeu de données, n'est pas en mesure d'apprendre correctement.

Faute de temps, nous n'avons pas pu tester plus de combinaisons d'hyperparamètres pour arriver à un modèle plus performant. Cela semble toute fois possible, au vu des résultats préliminaires vu en annexe. De plus, nous n'avons testé qu'un type de filtre, d'autres sont envisageables, comme évoqué par Delorme, 2023, ou bien également l'absence de filtre.

En somme, le réseau de neurones désigné au départ pour l'analyse EEG, que nous avons implémenté, serait capable de classifier des données électrophysiologiques, mais du fait de la complexité des données, le modèle réalise un apprentissage trop erratique pour être généralisable.

Bibliographie

- Chaparro-Cárdenas, S. L., Bautista, J. A. R., Contreras, W. G., Moreno-Chacón, A. L., & Vargas-Tangua, F. C. (2021). Plant electrophysiology : Bibliometric analysis, methods and applications in the monitoring of plant-environment interactions. *DYNA*, 88(218), 212-223. <https://doi.org/10.15446/dyna.v88n218.92405>
- Delorme, A. (2023). EEG is better left alone. *Scientific Reports*, 13(1), 2372. <https://doi.org/10.1038/s41598-023-27528-0>
- Dodd, A. N., Belbin, F. E., Frank, A., & Webb, A. A. R. (2015). Interactions between circadian clocks and photosynthesis for the temporal and spatial coordination of metabolism. *Frontiers in Plant Science*, 6. <https://doi.org/10.3389/fpls.2015.00245>
- Hodgkin, A. L., & Huxley, A. F. (1952). A quantitative description of membrane current and its application to conduction and excitation in nerve. *The Journal of Physiology*, 117(4), 500-544. <https://doi.org/10.1113/jphysiol.1952.sp004764>
- Hubbard, K. E., & Webb, A. A. R. (2015). Circadian Rhythms in Stomata : Physiological and Molecular Aspects. In S. Mancuso & S. Shabala (Éds.), *Rhythms in Plants : Dynamic Responses in a Dynamic Environment* (p. 231-255). Springer International Publishing. https://doi.org/10.1007/978-3-319-20517-5_9
- Lawhern, V. J., Solon, A. J., Waytowich, N. R., Gordon, S. M., Hung, C. P., & Lance, B. J. (2018). EEGNet : A compact convolutional neural network for EEG-based brain-computer interfaces. *Journal of Neural Engineering*, 15(5), 056013. <https://doi.org/10.1088/1741-2552/aace8c>
- Shim, J. S., Kubota, A., & Imaizumi, T. (2017). Circadian Clock and Photoperiodic Flowering in Arabidopsis : CONSTANS Is a Hub for Signal Integration. *Plant Physiology*, 173(1), 5-15. <https://doi.org/10.1104/pp.16.01327>

- Song, Y. Y., Zeng, R. S., Xu, J. F., Li, J., Shen, X., & Yihdego, W. G. (2010). Interplant Communication of Tomato Plants through Underground Common Mycorrhizal Networks. *PLOS ONE*, 5(10), e13324. <https://doi.org/10.1371/journal.pone.0013324>
- Tian, L., Sun, Y., Li, M., Wang, Y., Liu, J., & Liu, C. (2021). Research on Plant Growth State Classification Based on CNN- LSTM. *Journal of Physics: Conference Series*, 1993(1), 012036. <https://doi.org/10.1088/1742-6596/1993/1/012036>
- Volkov, A. G., Lang, R. D., & Volkova-Gugeshashvili, M. I. (2007). Electrical signaling in *Aloe vera* induced by localized thermal stress. *Bioelectrochemistry*, 71(2), 192-197. <https://doi.org/10.1016/j.bioelechem.2007.04.006>
- Volkov, A. G., Toole, S., & WaMaina, M. (2019). Electrical signal transmission in the plant-wide web. *Bioelectrochemistry*, 129, 70-78. <https://doi.org/10.1016/j.bioelechem.2019.05.003>
- Xu, G., Ren, T., Chen, Y., & Che, W. (2020). A One-Dimensional CNN-LSTM Model for Epileptic Seizure Recognition Using EEG Signal Analysis. *Frontiers in Neuroscience*, 14. <https://doi.org/10.3389/fnins.2020.578126>

Annexe

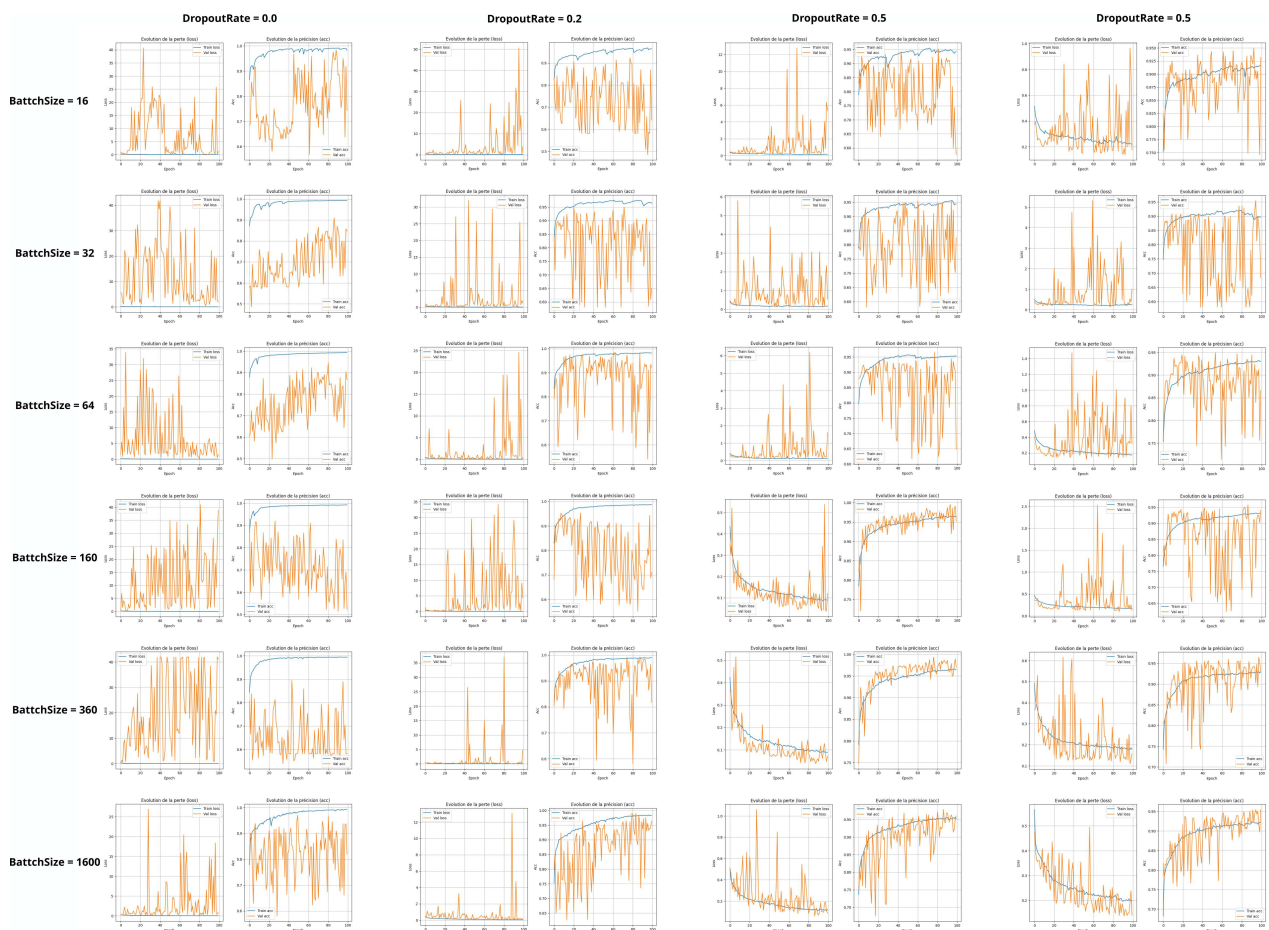


Figure 16. Graphiques représentant l'évaluation de la performance de l'apprentissage du modèle selon différents *batch size* et *dropout rate*. Pour chaque paire de graphe, à gauche est représenté l'évolution de la perte en fonction du nombre d'époques, et à droite l'évolution de la précision en fonction du nombre d'époques. Ces résultats préliminaires montrent qu'un *batch size* entre 160 et 360 et un *dropout rate* de 0.5 donnent un meilleur apprentissage.

Source de variation	Df	Sum Sq	Mean Sq	F value	Pr(>F)
Capteurs	7	248399	35486	132750.44	< 2.2e-16 ***
Classe	1	32	32	118.51	< 2.2e-16 ***
Capteurs:Classe	7	1410	201	753.61	< 2.2e-16 ***
Residuals	2305867	616383	0	-	-

Tableau 2. Résultats de l'ANOVA sur les données brutes.

Source de variation	Df	Sum Sq	Mean Sq	F value	Pr(>F)
Capteurs	7	132660	18951.5	93925.7	< 2.2e-16 ***
Classe	1	1220	1220.3	6048.1	< 2.2e-16 ***
Capteurs:Classe	7	2448	349.8	1733.5	< 2.2e-16 ***
Residuals	2305867	465256	0.2	-	-

Tableau 3. Résultats de l'ANOVA sur les données filtrées.




Figure 17. Visualisation graphique de la première heure d'enregistrement des données brutes durant la journée du 7 mai 2026. A gauche se trouve le signal brut, l'amplitude en fonction du temps, et à droite sa transformée de Fourier, l'amplitude en fonction des fréquences. On constate d'une part, une chute de l'amplitude des signaux dans les premières dizaines de minutes (entre 0 et 0.5), qui correspond au stress de la plante après qu'on ait inséré les électrodes. D'autre part, dans la transformée de Fourier, on remarque deux artefacts à 50 Hz et 150 Hz, comme vu dans la Figure 9.




Figure 18. Visualisation graphique de la première heure d'enregistrement des données filtrées durant la journée du 7 mai 2026. A gauche se trouve le signal brut, l'amplitude en fonction du temps, et à droite sa transformée de Fourier, l'amplitude en fonction des fréquences. Comme pour la Figure 17, on constate une chute de l'amplitude des signaux dans les premières dizaines de minutes. Mais cette fois ci, comme pour la Figure 10, le pic à 150 Hz est retiré par le filtre.