

Détection de la désactivation des LFP dans le système neuromusculaire de macaques lors d'une tâche "Reach and Grasp" par l'apprentissage machine. 2026

Hedi Zeghidi¹, Florian Chambellant¹, Ian Moreau-Debord², Eleonore Serrano²,
Stephan Quessy², Numa Dancause², Elizabeth Thomas¹

¹Université Bourgogne Europe, INSERM CAPS UMR 1093, 21000, Dijon, France

² Université de Montréal, Département de neurosciences, Faculté de médecine, Montréal (Québec)

28 janvier 2026

Résumé

Les lésions cérébrales, comme les AVC, perturbent l'activité neuromusculaire et entraînent des déficits moteurs majeurs. Nous évaluons plusieurs méthodes d'apprentissage automatique appliquées sur les potentiels de champ locaux (LFP) chez le macaque aux stades très précoces d'une inactivation cérébrale focale et réversible. L'apprentissage automatique permet de distinguer les essais avec et sans inactivation à partir des amplitudes spectrales et des décalages spectraux. Ces résultats, obtenus alors que l'animal pouvait encore saisir des objets, suggèrent une détection très précoce de l'inactivation neuronale grâce aux enregistrements extracellulaires.

Mots-clés

Intelligence artificielle ; tâche d'atteindre et de saisir ; potentiel de champ local multielectrode ; système neuromusculaire ; singe macaque

Abstract

Brain injuries such as stroke disrupt neuromuscular activity and cause significant motor impairments. In this study, we evaluate several machine learning methods using local field potentials (LFPs) in macaques at very early stages after focal, reversible brain inactivation. Machine learning was used to distinguish trials with and without inactivation using power spectral density amplitudes and spectral shifts. Because predictions were made shortly after inactivation—while the monkeys could still perform reach-and-grasp tasks—these results suggest the potential for very early detection of neuronal inactivation from extracellular field recordings.

Keywords

Artificial Intelligence ; Reach-and-Grasp Task ; Multielectrode Local Field Potential ; Neuromuscular System ; Macaque Monkey

1 Introduction

Les lésions cérébrales, telles que les accidents vasculaires cérébraux (AVC) ou les infarctus cérébraux, représentent aujourd'hui l'une des principales causes de mortalité dans le monde. Selon l'Organisation mondiale de la santé (OMS), en 2021, les lésions cérébrales figuraient parmi les principales causes de décès et d'invalidité à l'échelle mondiale, avec 11,9 millions de nouveaux cas d'AVC. Ces affections entraînent des altérations des capacités cognitives, telles que la prise de décision, la planification ou l'organisation, ainsi que des déficits moteurs, avec une démarche ralentie et des troubles de l'équilibre.

Sur le plan moteur, les muscles post-lésionnels présentent une capacité réduite à se contracter de manière isolée, ce qui favorise l'apparition de synergies anormales entre fléchisseurs et extenseurs [11, 2]. Au niveau de la main, les prises puissantes, nécessitant peu d'individualisation des doigts, sont privilégiées [7, 13], tandis que les mouvements nécessitant une coordination interarticulaire fine sont souvent altérés [1, 6].

Dans des études précédemment réalisées, comme celle de [4], l'analyse des variations des corrélations des activités neuronales des LFP montrait une concentration de l'activité dans la bande de fréquence Delta. Ces études ont également mis en évidence des changements dans les corrélations lors des différentes phases du mouvement. De plus, ces variations étaient également visibles lorsque l'on identifiait les groupes de neurones à l'aide d'un hierarchical clustering, permettant d'observer l'évolution de l'activité neuronale au fil des différentes étapes du mouvement. Cette étude a appliqué donc des méthodes d'intelligence artificielle à des cerveaux de singes sains pour regarder l'évolution ; une question demeure toutefois quant à la possibilité d'étendre ces approches à d'autres méthodes plus avancées comme l'apprentissage profond à des cerveaux de singes présentant des déficits.

Cette étude vise donc à évaluer des méthodes récentes d'apprentissage automatique pour détecter les altérations de l'activité neuronale consécutives à une lésion cérébrale. La détection repose sur la classification de l'activité neuronale enregistrée lors d'une tâche de Reach-and-Grasp chez le singe, comparée à celle mesurée 30 minutes après l'injection d'un agent pharmacologique simulant une lésion cérébrale. Différents modèles, allant des SVM à l'apprentissage profond, ont été entraînés sur plusieurs phases de la tâche et selon diverses méthodes de traitement, montrant des performances satisfaisantes selon plusieurs métriques.

2 Setup

2.1 Modèle expérimental

Les données ont été enregistrées chez deux macaques rhésus femelles (*Macaca mulatta*), le singe M (5,5 kg) et le singe S (5,7 kg), selon des procédures chirurgicales et comportementales déjà décrites [8]. Des réseaux multielectrodes ont été implantés dans les régions prémotrices ventrale (PMv) et dorsale (PMd) des deux hémisphères, ainsi que dans le cortex moteur primaire (M1) de l'hémisphère droit. Les signaux LFP ont été échantillonnés à 2035 Hz. Les LFP ont été extraits par filtrage entre 0 et 500 Hz, tandis que les potentiels d'action ont été filtrés entre 100 et 5000 Hz.

2.2 Tâche expérimentale




FIGURE 1 – Configuration expérimentale (image adaptée de [4]) illustrant les différentes étapes de l'essai : commencement de l'essai (Trial Start), dépôt de la boulette (Pellet Drop), sortie de la main (Hand Exit), début de la saisie (Start of Grasp) et fin de la saisie (End of Grasp).

Les singes étaient assis sur une chaise expérimentale adaptée aux primates, placée face à un distributeur de granulés alimentaires. Selon le bloc expérimental, une ouverture gauche ou droite était ouverte afin que le singe récupère une boulette de nourriture tombant dans un puits situé derrière une fente. La fente pourra s'orienter horizontalement ou verticalement, cette orientation variant selon les blocs, imposant une supination ou une pronation de la main à 90° (voir la Figure 1 avec la fente verticale).

Un essai commençait lorsque l'animal posait sa main sur la plaque d'accueil, située à 15 cm sous la fente à granulés.

Après un intervalle aléatoire de 800 ms à 2 s, une boulette de nourriture (Pellet Drop) était déposée automatiquement dans le puits. Le bruit associé à cette déposition constituait le signal de départ, après lequel l'animal disposait de 2 s pour retirer sa main de la plaque d'accueil (Hand Exit) et prendre la boulette. Ce positionnement de la main au départ et à la sortie était détecté par un premier capteur laser infrarouge.

Le moment où l'animal introduisait sa main dans la fente pour saisir la boulette (Start of Grasp) et celui où il retirait sa main de la fente (End of Grasp) étaient détectés par un deuxième capteur laser infrarouge. Le singe portait la boulette à sa bouche et replaçait sa main sur la plaque d'accueil, avec un intervalle de trois secondes entre chaque essai. Les animaux répétaient la tâche 25 fois pour chaque main et chaque orientation de la fente (blocs randomisés).

À l'issue de cette phase, un agent pharmacologique, le muscimol, simulant une lésion cérébrale, était injecté dans le cortex moteur primaire (M1) de l'hémisphère gauche. Après l'injection, le singe réalisait à nouveau 100 essais selon le même protocole qu'avant l'injection. Chaque singe a répété ce protocole à plusieurs reprises. Après le prétraitement, nous avons obtenu environ 1 200 essais répartis entre les deux classes.

2.3 Prétraitement

Les données ont été traitées à l'aide de scripts Matlab ([10]) et de FieldTrip ([9]). Les essais incorrects ont été exclus lorsque le temps de réaction était inférieur à 200 ms, la durée de l'atteinte supérieure à 350 ms ou la saisie inférieure à 200 ms. Les signaux LFP ont ensuite été filtrés par un filtre Butterworth passe-bas (200 Hz, ordre 6), puis le bruit à 60 Hz a été supprimé par un filtre coupe-bande (59–61 Hz). Les artefacts, avec des rafales irrégulières et des oscillations anormales de basse fréquence, qui ont été retirés à l'aide d'une analyse en composantes indépendantes (ICA) [3, 12].

3 Methodology

3.1 Modèles

Decision Tree. Un « Decision Tree » est un modèle d'apprentissage automatique supervisé, utilisé pour la classification ou la régression. Il prédit les résultats en divisant les données de manière récursive selon les valeurs de leurs variables, créant ainsi une structure en arbre de règles de décision : chaque nœud interne correspond à une condition sur une caractéristique, chaque branche représente l'issue de cette condition, et chaque feuille fournit la prédiction finale.

SVM. Une Machine à Vecteurs de Support (SVM) est un algorithme d'apprentissage supervisé utilisé pour la classification. Elle fonctionne en trouvant un hyperplan qui sépare les classes de données et en choisissant cet hyperplan pour maximiser la marge, c'est-à-dire la distance entre l'hyperplan et les points les plus proches de chaque classe, appelés vecteurs de support.

Random Forest . Random Forest est un algorithme d'apprentissage automatique supervisé qui construit une collection d'arbres de décision à l'aide de données d'entraînement rééchantillonnées de manière aléatoire et de caractéristiques sélectionnées de manière aléatoire, puis combine leurs prédictions individuelles pour produire un résultat final.

Modèle KNN . L'algorithme K-Nearest Neighbors (KNN) est une méthode de classification supervisée basée sur l'idée que les points de données similaires ont tendance à appartenir à la même classe (« qui se ressemble s'assemble »). Il prédit la classe de nouvelles données en examinant les classes des K points de données les plus proches dans l'espace des caractéristiques et en attribuant la classe la plus courante parmi celles-ci.

Modèle CNN . Un réseau neuronal convolutif (CNN) est un type de réseau neuronal à propagation directe conçu pour apprendre et extraire automatiquement des caractéristiques hiérarchiques à partir de données, généralement des images, en appliquant des filtres convolutifs (ou noyaux) qui glissent sur l'entrée pour capturer des motifs tels que les contours, les textures et les formes, les filtres appris étant optimisés pendant l'entraînement afin d'améliorer les performances spécifiques à la tâche.

Vision Transformer . *Vision Transformer* (ViT) sont un type d'architecture de réseau neuronal pour la vision par ordinateur qui adapte le modèle des transformers, initialement développé pour le traitement du langage naturel, aux données d'images. Plutôt que de traiter l'image dans son ensemble, les ViT la divisent en patchs de taille fixe, transforment chaque patch en vecteur (embedding) et traitent ensuite la séquence de ces vecteurs à l'aide de mécanismes d'auto-attention. L'auto-attention permet au modèle de pondérer l'importance relative de chaque patch par rapport aux autres, en capturant les relations et dépendances à longue portée entre différentes parties de l'image. Cette approche permet au modèle d'apprendre des représentations riches et globales, utiles pour des tâches telles que la classification d'images, la détection d'objets ou la segmentation.

3.2 Metrics

Pour évaluer la capacité des modèles à détecter la désactivation, nous avons utilisé plusieurs indicateurs de performance, notamment la précision, le recall, le F1-score et l'accuracy. Ces indicateurs ont été choisis en raison du léger déséquilibre entre les deux classes (55% pour la classe non désactivée et 45% pour la classe désactivée) et afin d'obtenir une vision globale des performances. Ils sont dérivés de la matrice de confusion, qui résume les résultats d'une tâche de classification binaire comportant deux classes : positive et négative.

Précision . La précision quantifie la fiabilité des prédictions d'une classe donnée, en mesurant la proportion de vrais positifs parmi tous les positifs prédits. Elle est définie comme suit :

$$\text{Precision} = \frac{TP}{TP + FP}$$

Recall . Recall quantifie la capacité d'un modèle à identifier toutes les instances d'une classe donnée, en mesurant la proportion d'instances positives réelles qui ont été correctement prédites. Il peut être exprimé comme suit :

$$\text{Recall} = \frac{TP}{TP + FN}$$

F1-score . Le F1-score représente la moyenne de la précision et du rappel, fournissant ainsi une mesure unique qui équilibre les deux. Il est calculé comme suit :

$$\text{F1-score} = \frac{2 * TP}{2 * TP + FP + FN}$$

Accuracy . Accuracy mesure l'exactitude des prédictions du modèle en calculant la proportion de résultats corrects parmi le nombre total de résultats.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

3.3 Configuration d'entraînement

Dans l'ensemble de nos modèles classiques, les données ont été réparties en 80% pour l'entraînement et 20% pour le test. Les procédures d'entraînement variaient selon les modèles. Pour les modèles KNN, SVM et Random Forest, l'entraînement a été réalisé avec une validation croisée et une optimisation des hyperparamètres, en choisissant le F1-score comme critère pour déterminer les meilleurs paramètres.

Pour la première approche de classification, nous avons entraîné des modèles d'apprentissage profond, l'ensemble d'entraînement a été subdivisé en 60% pour l'entraînement, 20% pour la validation et 20% pour le test. Cette répartition offre un équilibre classique entre capacité d'apprentissage et robustesse de l'évaluation. Le modèle a été sauvegardé durant l'entraînement chaque fois que la validation loss diminuait. Le taux d'apprentissage initial était fixé à $1e-3$. Dans l'ensemble des différentes périodes étudiées, nous avons observé une convergence de la loss d'entraînement et de validation après environ une quinzaine d'epochs.

Pour interpréter ces prédictions, nous avons utilisé la méthode Grad-CAM (Gradient-weighted Class Activation Mapping), une technique d'interprétabilité adaptée aux réseaux de neurones convolutionnels, qui permet de visualiser les régions de l'image ayant le plus d'influence sur la prédiction d'une classe donnée. Grad-CAM calcule le gradient de la sortie associée à la classe d'intérêt par rapport aux cartes d'activation d'une couche convolutionnelle, puis utilise ces gradients pour pondérer et combiner les cartes d'activation, produisant ainsi une carte de chaleur mettant en évidence les zones déterminantes. Cette approche rend les décisions des CNN plus transparentes, permet de vérifier que le modèle se concentre sur des caractéristiques pertinentes, de détecter d'éventuels biais ou erreurs, et de communiquer les résultats de manière visuelle et intuitive, ce qui est essentiel dans un contexte scientifique ou biomédical.

Pour la seconde approche de classification, basée sur les spectrogrammes, nous avons calculé la densité spectrale de puissance (PSD) et extrait le classement des amplitudes maximales pour les cinq bandes de fréquences (Delta, Theta, Alpha, Beta et Gamma). Ce classement a ensuite servi à entraîner un Decision Tree et une Random Forest afin d'évaluer si la désactivation neuronale entraînait des modifications dans la hiérarchie des bandes de fréquences.

4 Résultats

Pour détecter la désactivation neuronale, nous avons testé deux approches basées sur les spectrogrammes : l'utilisation directe des spectrogrammes et l'exploitation du classement des amplitudes maximales.

4.1 Détection avec les spectrogrammes normalisés des LFP

Afin d'identifier la désactivation neuronale, les signaux LFP ont été transformés en spectrogrammes couvrant une bande de fréquences de 0,5 à 100,5 Hz, avec un pas de 2 Hz (2,5; 4,5, etc.), puis normalisés par rapport à la période d'observation. Les données ont été sélectionnées sur l'ensemble des fréquences et sur des fenêtres temporelles de 500 ms, à différents moments décrits plus loin dans l'article. Les signaux ont ensuite été moyennés par zone d'enregistrement (IPMv, rPMv, lPMd, rPMd, M1).

Les données obtenues étaient ainsi organisées sous forme de tenseurs tridimensionnels, comprenant 5 régions, 51 bandes de fréquences et 50 pas de temps. Différentes phases des essais ont été analysées afin d'évaluer la capacité à détecter la désactivation neuronale à différents moments du comportement : avant la réaction du singe (500 ms avant le Pellet Drop), au début du mouvement (250 ms avant et après la sortie de la main), et avant le début de la prise (500 ms avant le début de la saisie).

4.1.1 Période d'observation

Les résultats présentés dans le tableau 1 indiquent que, pour cette période, les meilleurs scores sont ex aequo pour le modèle CNN et le ViT, avec une accuracy et un F1-score de 77%. On observe par ailleurs qu'il n'existe pas de différence notable entre les valeurs de l'accuracy et du F1-score. À l'inverse, les performances les plus faibles sont obtenues avec le modèle le plus simple, le KNN.

Modèles	Precision	Recall	F1-score	Accuracy
SVM	64%	64%	64%	64%
Random Forest	78%	69%	72%	72%
KNN	52%	52%	52%	53%
Dense Model	53%	53%	52%	52%
CNN Model	77%	76%	77%	77%
ViT	77%	76%	77%	77%

TABLE 1 – Performances de classification des différents modèles pour distinguer l'activation et la désactivation neuronales pour la période d'observation

L'analyse de la matrice de confusion du modèle CNN montre que les erreurs se produisaient surtout lorsque le modèle prédisait qu'il n'y avait pas de désactivation, alors qu'en réalité l'activité neuronale était désactivée. Par ailleurs, l'examen de la dernière couche convolutionnelle du modèle CNN (voir la Figure 2) révèle que les informations les plus discriminantes pour déterminer la désactivation sont localisées juste avant le Pellet Drop entre -125ms et 0ms, et concernent principalement les bandes de fréquences Delta (0,5–4Hz), Theta (4–7Hz), Alpha (7–12Hz), Beta (12–16.5Hz) et Gamma (36.5–42.5Hz et 94.5–100.5 Hz).

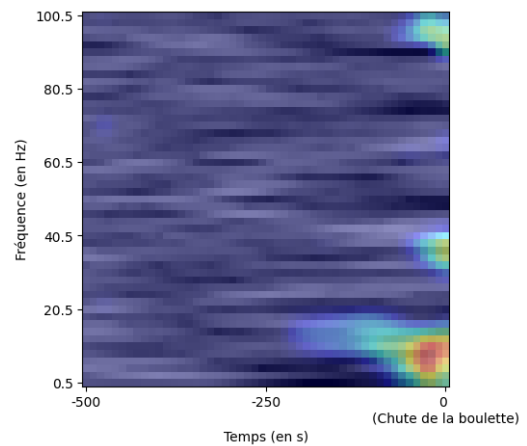


FIGURE 2 – Grad-CAM du modèle CNN pour la classe désactivée, 500 ms avant le dépôt de la boulette

4.1.2 Période de la sortie de la main

Les résultats présentés dans le tableau 2 montrent que, pour cette période, le modèle CNN obtient les meilleures performances, avec une accuracy et un F1-score de 78%.

Modèles	Precision	Recall	F1-score	Accuracy
SVM	72%	72%	72%	72%
Random Forest	78%	76%	77%	78%
KNN	53%	53%	53%	54%
Dense Model	68%	68%	68%	68%
CNN Model	78%	78%	78%	78%
ViT	76%	76%	76%	76%

TABLE 2 – Performances de classification des différents modèles pour distinguer l'activation et la désactivation neuronales au début de la prise

L'analyse de la dernière couche convolutionnelle du CNN modèle révèle que la période précédant la sortie de la main est la plus informative, principalement dans les basses bandes de fréquences : Delta, Theta et Alpha.

4.1.3 Période du début de la prise

Ici, en considérant les 500 ms précédant le début de la prise, nous observons de meilleurs résultats pour l'ensemble des modèles. Toutefois, ces performances ne dépassent pas celles obtenues sur d'autres périodes. Le meilleur modèle

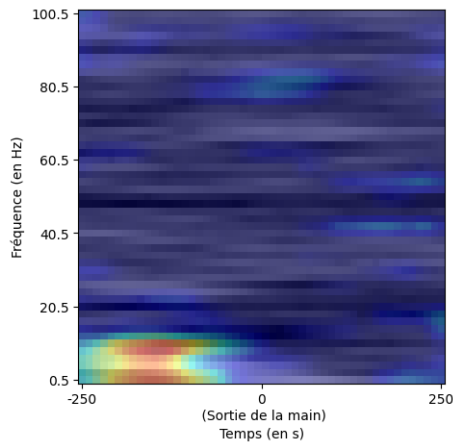


FIGURE 3 – Grad-CAM du modèle CNN pour la classe désactivée, 250ms avant et après la sortie de la main

reste le Random Forest, avec un F1-score de 76% et une accuracy de 78%.

Modèles	Precision	Recall	F1-score	Accuracy
SVM	69%	69%	69%	69%
Random Forest	79%	76%	76%	78%
KNN	50%	50%	50%	51%
Dense Model	73%	73%	73%	73%
CNN Model	74%	74%	74%	74%
ViT	76%	77%	76%	76%

TABLE 3 – Performances de classification des différents modèles pour distinguer l'activation et la désactivation neuronales pour la période du début de la prise

Si nous analysons la dernière couche convolutionnelle du CNN modèle, nous trouvons que les informations les plus importantes pour déterminer les classes se trouvent dans les basses fréquences de Delta, Theta et Alpha. Et, elles se concentrent surtout entre -375ms et -250ms avant le début de la saisie.




FIGURE 4 – Grad-CAM du modèle CNN pour la classe désactivée, 500ms avant le début de la saisie

4.2 Détection avec le "Power Density Spectral" des LFP

Dans cette partie, nous avons choisi de nous concentrer sur les régions IPMv et IPMd, car elles sont situées à proximité du site d'injection du muscimol. Nous avons analysé la classification selon les différentes phases de l'essai (Observation, Reaction, Reach and Grasp). Pour ces données, seuls des modèles interprétables pour ces données ont été utilisés, à savoir Decision Tree et Random Forest.

Modèles	Precision	Recall	F1-score	Accuracy
Decision Tree OBS	75%	74%	75%	75%
Decision Tree REACT	64%	64%	63%	63%
Decision Tree REACH	67%	66%	66%	68%
Decision Tree GRASP	65%	65%	65%	66%
Random Forest OBS	75%	75%	75%	76%
Random Forest REACT	71%	71%	71%	72%
Random Forest REACH	69%	68%	69%	70%
Random Forest GRASP	67%	67%	67%	68%

TABLE 4 – Performances des différents modèles utilisant les densités spectrales de puissance (PSD)

En analysant l'ensemble des résultats, on observe que les meilleures performances sont obtenues durant la période d'observation. Les scores se situent entre 65% et 75%, ce qui indique que les PSD présentent des changements notables suite à la désactivation neuronale.




FIGURE 5 – Decision Tree : importance des positions dans les deux classements des zones

Dans la Figure 5, on peut identifier quelles positions dans le classement des bandes de fréquences, établi à partir des amplitudes maximales, influencent le plus la classification. Pour la zone IPMv, les rangs extrêmes — la bande présentant l'amplitude la plus élevée et celle présentant l'amplitude la plus faible — sont les plus déterminants. Pour la zone IPMd, les contributions majeures proviennent des troisième et quatrième bandes de fréquences. Un phénomène similaire est observé avec le modèle Random Forest, comme illustré dans la Figure 6.




FIGURE 6 – Random forest : importance des positions dans les deux classements des zones

5 Conclusion

Cette étude montre que les méthodes d'apprentissage automatique appliquées aux spectrogrammes de LFP permettent de détecter automatiquement les activités neuronales associées à une inactivation cérébrale focale et réversible. Des informations discriminantes émergent dans les spectrogrammes pour identifier la désactivation, en particulier autour du début du mouvement, et se situent principalement dans les bandes de basses fréquences, telles que delta, theta et alpha. Ces observations sont cohérentes avec les études antérieures de [4, 5], qui indiquaient que l'essentiel de l'activité lors des mouvements de Reach-and-Grasp se concentre dans la bande Delta. D'autres signatures sont également mises en évidence dans les PSD, à travers des variations des amplitudes maximales sur les cinq bandes de fréquences. Ces différences sont particulièrement marquées dans la région IPMv, notamment pour les bandes de fréquences extrêmes (les plus basses et les plus hautes).

Par ailleurs, nous supposons que cette désactivation pourrait aussi être mise en évidence en comparant l'activité neuronale entre les deux hémisphères. Dans le même objectif d'affiner l'analyse, nous prévoyons également d'examiner l'évolution de nos prédictions en nous concentrant sur un seul type de mouvement plutôt que sur l'ensemble des essais ; par exemple, en focalisant l'analyse sur le bras droit, nous nous attendons à observer des différences plus prononcées qu'avec le bras gauche.

Remerciements

Ce travail est financé par une collectivité territoriale dans le cadre du projet CORN. Les données ont été acquises, transmises par l'Université de Montréal, Département de neurosciences, Faculté de médecine, Montréal.

Références

[1] Sarah Astill and Andrea Utley. Coupling of the reach and grasp phase during catching in children with de-

velopmental coordination disorder. *Journal of motor behavior*, 40 :315–23, 07 2008.

- [2] Benjamin Baak, Otmar Bock, Anna Dovern, Jochen Saliger, Hans Karbe, and Peter H. Weiss. Deficits of reach-to-grasp coordination following stroke : Comparison of instructed and natural movements. *Neuropsychologia*, 77 :1–9, 2015.
- [3] Anthony Bell and Terrence Sejnowski. An information-maximization approach to blind separation and blind deconvolution. *Neural Computation*, 7 :1129–1159, 11 1995.
- [4] Florian Chambellant, Ali Falaki, Ian Moreau-Debord, Robert French, Eleonore Serrano, Stephan Quessy, Numa Dancause, and Elizabeth Thomas. Variations in clustering of multielectrode local field potentials in the motor cortex of macaque monkeys during a reach-and-grasp task. *eneuro*, 11 :ENEURO.0047–24.2024, 09 2024.
- [5] Ali Falaki, Stephan Quessy, and Numa Dancause. Differential modulation of local field potentials in the primary and premotor cortices during ipsilateral and contralateral reach to grasp in macaque monkeys. *Journal of Neuroscience*, 44(21), 2024.
- [6] Mindy Levin. Interjoint coordination during pointing movements is disrupted in spastic hemiparesis. *Brain : a journal of neurology*, 119 (Pt 1) :281–93, 03 1996.
- [7] Sheng Li, Mark L Latash, Guang H Yue, Vlodek Sienionow, and Vinod Sahgal. The effects of stroke and age on finger interaction in multi-finger force production tasks. *Clinical Neurophysiology*, 114(9) :1646–1655, 2003.
- [8] Ian Moreau-Debord, Éléonore Serrano, Stephan Quessy, and Numa Dancause. Rapid and bihemispheric reorganization of neuronal activity in premotor cortex after brain injury. *The Journal of Neuroscience*, 41 :9112 – 9128, 2021.
- [9] Robert Oostenveld, Pascal Fries, Eric Maris, and Jan-Mathijs Schoffelen. Fieldtrip : Open source software for advanced analysis of meg, eeg, and invasive electrophysiological data. *Computational intelligence and neuroscience*, 2011 :156869, 01 2011.
- [10] The MathWorks Inc. Matlab.
- [11] Thomas E. Twitchell. The restoration of motor function following hemiplegia in man. *Brain*, 74(4) :443–480, 12 1951.
- [12] Nathan Whitmore and Shih-Chieh Lin. Unmasking local activity within local field potentials (lfps) by removing distal electrical signals using independent component analysis. *NeuroImage*, 132, 02 2016.
- [13] Jing Xu, Adrian Haith, and John Krakauer. Motor control of the hand before and after stroke. *Clinical Systems Neuroscience*, pages 271–289, 12 2015.