

Titre: Approches pour la détection automatique de présence sexuelle en temps réel via analyse d'EEG
Title: [Approches pour la détection automatique de présence sexuelle en temps réel via analyse d'EEG](#)

Auteur: Clément Jacques Pierre Galaup
Author: [Clément Jacques Pierre Galaup](#)

Date: 2025

Type: Mémoire ou thèse / Dissertation or Thesis

Référence: Galaup, C. J. P. (2025). Approches pour la détection automatique de présence sexuelle en temps réel via analyse d'EEG [Mémoire de maîtrise, Polytechnique Montréal]. PolyPublie. <https://publications.polymtl.ca/69275/>
Citation: [Galaup, C. J. P. \(2025\). Approches pour la détection automatique de présence sexuelle en temps réel via analyse d'EEG \[Mémoire de maîtrise, Polytechnique Montréal\]. PolyPublie. https://publications.polymtl.ca/69275/](#)

Document en libre accès dans PolyPublie

Open Access document in PolyPublie

URL de PolyPublie: <https://publications.polymtl.ca/69275/>
PolyPublie URL: [https://publications.polymtl.ca/69275/](#)

Directeurs de recherche: Lama Séoud, & Patrice Renaud
Advisors: [Lama Séoud](#), [Patrice Renaud](#)

Programme: Génie Informatique
Program: [Génie Informatique](#)

POLYTECHNIQUE MONTRÉAL

affiliée à l'Université de Montréal

**Approches pour la détection automatique de présence sexuelle en temps réel
via analyse d'EEG**

CLÉMENT JACQUES PIERRE GALAUP

Département de génie informatique et génie logiciel

Mémoire présenté en vue de l'obtention du diplôme de *Maîtrise ès sciences appliquées*
Génie informatique

Octobre 2025

POLYTECHNIQUE MONTRÉAL

affiliée à l'Université de Montréal

Ce mémoire intitulé :

**Approches pour la détection automatique de présence sexuelle en temps réel
via analyse d'EEG**

présenté par **Clément Jacques Pierre GALAUP**

en vue de l'obtention du diplôme de *Maîtrise ès sciences appliquées*

a été dûment accepté par le jury d'examen constitué de :

Thomas HURTUT, président

Lama SÉOUD, membre et directrice de recherche

Patrice RENAUD, membre et codirecteur de recherche

Tarik BOUKHALFI, membre externe

DÉDICACE

*À ma famille pour m'avoir accordé une confiance, un soutien et un amour inconditionnel
depuis l'autre côté de l'océan.*

*À mes amis, mes proches, mes potes, ceux et celles dont j'ai eu la chance de croiser le
chemin. Ceux qui sont restés et ceux qui sont partis.*

REMERCIEMENTS

Je tiens tout d'abord à remercier ma directrice et mon directeur de recherche, Lama Séoud et Patrice Renaud, pour ces années de maîtrise qui n'ont été possibles que grâce à leur soutien, leurs encouragements et leurs conseils, autant techniques que moraux. Ils ont toujours été là pour moi malgré mes nombreuses erreurs, avec une patience et une bienveillance inestimables. Leur confiance en moi, même dans les moments où j'avais cessé de croire en mes propres capacités, m'a permis de persévérer et de me relever. Un grand merci aussi à Matthieu Brideau-Duquette et Sarah Saint-Pierre Côté, qui m'ont accepté dans leur laboratoire, m'ont permis d'utiliser les données issues de leurs dures années de labeur et d'avoir pu apporter avec ce mémoire ma petite pierre à l'édifice qu'ils sont en train de construire à l'INPLPP. Sans leurs conseils et leur soutien, ce projet n'aurait certainement jamais abouti. Je tiens aussi à saluer tous les membres du VisionIC, mon laboratoire de Polytechnique Montréal, qui ont toujours su m'inclure dans leur joie et bonne humeur malgré mon statut mérité de fantôme du laboratoire. Des collègues qui ont toujours su m'épauler quand le besoin s'est fait sentir et que je suis heureux et fier de pouvoir aujourd'hui appeler des amis. Je remercie également toutes les personnes que j'ai pu rencontrer durant ma maîtrise au travers de la vie étudiante de Polytechnique Montréal. Merci à mes amis du PUB pour avoir fourni le réconfort après l'effort, merci à Polyshow de m'avoir tant appris et merci à toute l'équipe de Polydanse qui m'a fait vivre une passion au travers de moments de danse. Tant d'aventures parallèles incroyables sans lesquelles je n'aurais sans doute jamais trouvé la force de finir l'aventure qu'a été cette maîtrise. Merci à ma famille étendue et à mes amis de m'avoir soutenu et de n'avoir qu'un petit peu rigolé quand j'ai annoncé que j'allais partir de l'autre côté de l'Atlantique regarder les ondes cérébrales pour prédire des érections (mais c'est pour une bonne cause : c'est pour diagnostiquer des pédophiles, et en plus c'est en VR). Enfin, un immense merci à mes proches, mes parents, mon frère et ma sœur pour leur soutien constant malgré la distance, pour les encouragements dans les moments où la motivation se faisait légère, les célébrations pour partager chacune des petites victoires de ce projet. Sans eux je n'aurais jamais pu ni finir cette maîtrise, ni devenir la personne que je suis aujourd'hui.

RÉSUMÉ

La détection de la présence sexuelle constitue un enjeu important en contexte médico-légal et clinique, notamment pour l'évaluation du risque de récidive chez les auteurs d'infractions sexuelles. Ce mémoire propose une exploration de diverses méthodes non invasives de détection en temps réel de l'impulsion sexuelle à partir des seuls signaux issus de l'électroencéphalogramme (EEG), en supprimant la pléthysmographie pénienne (PPG). L'impulsion sexuelle est définie comme une réponse physiologique rapide à un stimulus sexuel, distincte de la présence sexuelle, qui relève d'une expérience subjective plus complexe.

L'étude repose sur des immersions virtuelles de participants masculins dans des scénarios neutres et érotiques. Trois approches de classification issues de divers domaines de la littérature sont comparées : réseau de neurones convolutifs (Convolutional Neural Networks) (CNN) appliqué à des spectrogrammes, extraction de caractéristiques profondes via un réseau asymétrique et régional de neurones convolutifs (Regional-Asymmetric Convolutional Neural Network) (RA-CNN), et modèle de perceptron multi-couches (Multi-Layer Perceptron) (MLP) basé sur des caractéristiques entropiques.

Malgré des résultats prometteurs intra-participants, la généralisation à des individus inconnus reste limitée et le raffinage est nécessaire pour obtenir des performances satisfaisantes. Ces travaux montrent la prévalence des modèles MLP basés sur des caractéristiques d'entropie Fuzzy et met en avant leurs limites notamment la nécessité de prétraitements et d'extraction de caractéristiques computationnellement lourdes pour le moment incompatibles avec le temps réel. Des pistes d'amélioration sont proposées, telles que l'optimisation GPU et l'intégration de données oculométriques. Ce travail ouvre la voie à des outils non invasifs pour l'évaluation clinique de la réponse sexuelle.

ABSTRACT

Detecting sexual presence is a major concern in clinical and forensic contexts, particularly for assessing the risk of recidivism among sexual offenders. This thesis introduces an exploration of non-invasive methods for real-time detection of sexual impulse using only EEG signals, eliminating the need for PPG. Sexual impulse is defined as a rapid physiological response to sexual stimuli, distinct from sexual presence, which involves a more complex and subjective experience. The study is based on immersive virtual scenarios involving male participants exposed to both neutral and erotic content. Three classification approaches drawn from various fields are compared: CNN applied to spectrograms, deep feature extraction via RA-CNN, and MLP models based on entropy features. While intra-participant results are promising, generalisation to unseen individuals remains limited, requiring fine-tuning to achieve satisfactory performance. This work highlights the effectiveness of MLP models based on fuzzy entropy features, while also underscoring their limitations due to computationally intensive preprocessing and feature extraction, which are incompatible with real-time use. Potential improvements include GPU optimization and the integration of eye-tracking data. This research paves the way for non-invasive tools to assess sexual response in clinical settings.

TABLE DES MATIÈRES

DÉDICACE	iii
REMERCIEMENTS	iv
RÉSUMÉ	v
ABSTRACT	vi
LISTE DES TABLEAUX	x
LISTE DES FIGURES	xi
LISTE DES SIGLES ET ABRÉVIATIONS	xii
LISTE DES ANNEXES	xiii
CHAPITRE 1 INTRODUCTION	1
CHAPITRE 2 REVUE DE CONNAISSANCES ET DE LA LITTÉRATURE	3
2.1 Définition de la présence sexuelle	3
2.2 Détection physiologique de la présence sexuelle	4
2.2.1 Pléthysmographie génitale	4
2.2.2 Électroencéphalographie	4
2.3 Prédiction de la présence sexuelle	6
2.4 Analyse de l'EEG pour la reconnaissance d'émotions et autres domaines connexes	6
2.4.1 Pourquoi regarder le domaine de reconnaissance d'émotions ?	6
2.4.2 Architectures utilisées pour la reconnaissance d'émotions	7
2.4.3 Architectures utilisées dans d'autres domaines	8
CHAPITRE 3 OBJECTIFS DE RECHERCHE	9
CHAPITRE 4 MÉTHODES ET EXPÉRIENCES	11
4.1 Données disponibles et Prétraitement	11
4.1.1 Explication des conditions expérimentales	11
4.1.2 Formatage pour une utilisation en temps réel et étiquetage	12
4.1.3 Prétraitement par analyse par composantes indépendantes	13
4.2 Classification par analyse de spectrogrammes	14
4.2.1 Extraction de spectrogrammes	14

4.2.2	Architectures CNN pour analyse de spectrogrammes	14
4.3	Classification par extraction de caractéristiques temporelles profondes	16
4.3.1	Représentation spatiale de l'EEG	16
4.3.2	Extraction de caractéristiques par convolutions sur l'axe temporel	17
4.3.3	Extraction de caractéristiques régionales avec un CNN	18
4.3.4	Extraction de caractéristiques asymétriques	20
4.3.5	Architecture du réseau convolutif régional asymétrique (RA-CNN)	20
4.4	Classifications par analyses de caractéristiques entropiques	22
4.4.1	Extraction de caractéristiques entropiques	22
4.4.2	Architectures MLP basées sur l'entropie	24
4.5	Protocole expérimental	26
4.5.1	Séparation des données temporellement ou par participant	26
4.5.2	Ajout ou non d'un prétraitement par analyse par composantes indépendantes (Independent Component Analysis) (ICA)	28
4.5.3	Généralisation à des patients inconnus et raffinage	28
4.5.4	Visualisation de l'inférence des modèles	29
CHAPITRE 5 RÉSULTATS		30
5.1	Comparaison des modèles sur des patients connus	30
5.1.1	Résultats sur les données brutes	30
5.1.2	Résultats sur les données avec ICA	31
5.2	Généralisation aux patients inconnus	32
5.2.1	Résultats sans fine-tuning	32
5.2.2	Résultats avec raffinement du modèle général	33
5.2.3	Résultats avec modèles personnalisés	34
5.3	Analyse qualitative des modèles par visualisation de l'inférence	36
CHAPITRE 6 DISCUSSION		39
6.1	Rappel des contraintes souhaitées pour des futures utilisations des modèles	39
6.1.1	Utilisation en temps réel	39
6.1.2	Généralisation facile à des patients inconnus	39
6.2	Nécessité du prétraitement par ICA	40
6.2.1	Incompatibilité du prétraitement original avec une utilisation en temps réel	40
6.2.2	Prétraitement alternatif compatible avec des fenêtres courtes	40
6.3	Utilisation de modèles basés sur l'entropie	41
6.3.1	Complexité et temps de calcul des caractéristiques entropiques	41
6.3.2	Calcul parallélisable possible	41

CHAPITRE 7 CONCLUSION	42
7.1 Synthèse des travaux	42
7.1.1 Performance sur participants connus	42
7.1.2 Généralisation aux participants inconnus	42
7.2 Limites de la solution proposée	43
7.2.1 Mauvaise généralisation	43
7.2.2 Incompatibilité avec le temps réel	43
7.3 Améliorations futures	43
7.3.1 Optimisation du calcul entropique	44
7.3.2 Prétraitement causal et automatisé	44
7.3.3 Améliorer la robustesse à de nouveaux environnements immersifs	44
7.3.4 Validation sur un plus grand échantillon	44
RÉFÉRENCES	45
ANNEXES	47

LISTE DES TABLEAUX

Tableau 4.1	Architecture du modèle SpectroCNN_3 avec nombre de paramètres	15
Tableau 4.2	Architecture du modèle SpectroCNN_5 avec nombre de paramètres	16
Tableau 4.3	Architecture du modèle SpectroCNN_Res avec nombre de paramètres	17
Tableau 4.4	Positionnement spatial des électrodes frontales dans une matrice 4x9	18
Tableau 4.5	Architecture du modèle MLP_Baseline avec nombre de paramètres	25
Tableau 4.6	Architecture du modèle MLP_DCE avec nombre de paramètres	25
Tableau 4.7	Architecture du modèle MLP_Baseline+DCE avec nombre de paramètres	26
Tableau 5.1	Performance des modèles sur les données brutes des patients connus	30
Tableau 5.2	Performance des modèles sur les ensembles de test, entraînement et validation des données brutes.	32
Tableau 5.3	Performance des modèles sur les données avec prétraitement ICA	33
Tableau 5.4	Exactitudes des modèles les plus performants sur les données test des participants inconnus	33
Tableau 5.5	Exactitudes en fonction du pourcentage de données utilisées pour le raffinement des modèles Fuzzy_MLP_Baseline_ $\delta\theta\alpha\beta$	34
Tableau 5.6	Exactitudes en fonction du pourcentage de données utilisées pour le raffinement des modèles d'architecture Fuzzy_MLP_Baseline_ $\alpha\beta$	34
Tableau 5.7	Exactitudes en fonction du pourcentage de données utilisées pour le raffinement des modèles d'architecture Fuzzy_MLP_Baseline+DCE_ $\alpha\beta$	35
Tableau 5.8	Exactitudes en fonction du pourcentage de données utilisées pour l'entraînement d'un modèle Fuzzy_MLP_Baseline_ $\delta\theta\alpha\beta$	35
Tableau 5.9	Exactitudes en fonction du pourcentage de données utilisées pour l'entraînement d'un modèle Fuzzy_MLP_Baseline_ $\alpha\beta$	36
Tableau 5.10	Exactitudes moyennes selon la proportion de données d'entraînement d'un modèle Fuzzy_MLP_Baseline+DCE_ $\alpha\beta$	36

LISTE DES FIGURES

Figure 4.1	En vert, intervalle des instants correspondant à un état excité pour le scénario VidSex pour un participant.	13
Figure 4.2	Répartition spatiale des électrodes EEG.	18
Figure 4.3	Extraction de caractéristiques profondes sur l'axe temporel.	19
Figure 4.4	Extraction de caractéristiques régionales de haut niveau.	19
Figure 4.5	Extraction de caractéristiques asymétriques de haut niveau.	21
Figure 4.6	Architecture complète du réseau RA_CNN	22
Figure 4.7	Illustration de la séparation temporelle des deux enregistrements d'un patient en données d'entraînement, de validation et de test	28
Figure 5.1	Inférence du modèle général et raffiné sur le Participant Test 1 . . .	38
Figure 5.2	Inférence du modèle général et raffiné sur le Participant Test 8 . .	38
Figure A.1	Inférence du modèle Fuzzy_MLP_Baseline_ $\delta\theta\alpha\beta$ général et raffiné sur Participant test₁	47
Figure A.2	Inférence du modèle Fuzzy_MLP_Baseline_ $\delta\theta\alpha\beta$ général et raffiné sur Participant test₂	47
Figure A.3	Inférence du modèle Fuzzy_MLP_Baseline_ $\delta\theta\alpha\beta$ général et raffiné sur Participant test₃	48
Figure A.4	Inférence du modèle Fuzzy_MLP_Baseline_ $\delta\theta\alpha\beta$ général et raffiné sur Participant test₄	48
Figure A.5	Inférence du modèle Fuzzy_MLP_Baseline_ $\delta\theta\alpha\beta$ général et raffiné sur Participant test₅	49
Figure A.6	Inférence du modèle Fuzzy_MLP_Baseline_ $\delta\theta\alpha\beta$ général et raffiné sur Participant test₆	49
Figure A.7	Inférence du modèle Fuzzy_MLP_Baseline_ $\delta\theta\alpha\beta$ général et raffiné sur Participant test₇	50
Figure A.8	Inférence du modèle Fuzzy_MLP_Baseline_ $\delta\theta\alpha\beta$ général et raffiné sur Participant test₈	50

LISTE DES SIGLES ET ABRÉVIATIONS

EEG	Électroencéphalogramme
PPG	Pléthysmographie pénienne
VR	Réalité virtuelle (Virtual Reality)
ADL	Couche de différence assymétrique
DCE	Entropie croisée dynamique
MLP	Perceptron multicouches
CNN	Réseau de neurones convolutif (Convolutional Neural Network)
RNN	Réseau neuronal récurrent (Recurrent Neural Network)
ICA	Analyse par composantes indépendantes
INPLPP	Institut national de psychiatrie légale Philippe Pinel
LSTM	Réseaux à mémoire long-court terme (Long Short-Term Memory)
GRU	Unité récurrente à barrière (Gated Recurrent Unit)
RA-CNN	Réseau CNN Régional et Assymétrique (Regional-Asymmetric Convolutional Neural Network)

LISTE DES ANNEXES

Annexe A	Inférence des modèles généraux et raffinés sur les participants test . . .	47
----------	--	----

CHAPITRE 1 INTRODUCTION

Dans un contexte médico-légal, les agents virtuels peuvent être utilisés pour susciter des réponses motrices sexuelles et perceptives permettant d'identifier des troubles et des déviances sexuelles. En particulier, cela permet de distinguer les téléiophiles (individus sexuellement attirés par les adultes) des pédophiles [1]. De plus, la recherche a démontré que les environnements virtuels hautement immersifs ont tendance à améliorer les évaluations du réalisme ainsi que les évaluations de l'attrait sexuel [2].

À l'Institut national de psychiatrie légale Philippe Pinel (INPLPP), nos partenaires et leurs collaborateurs ont mis au point un examen pour évaluer le risque de récidive de sujets ayant commis un crime sexuel [1]. Cet examen consiste à immerger le sujet dans un environnement virtuel impliquant des stimuli sexuels humains tridimensionnels et à enregistrer plusieurs types de signaux physiologiques. L'électroencéphalographie EEG permet de recueillir l'activité électrique cérébrale. La pléthysmographie sexuelle PPG mesure la réponse génitale d'excitation chez les sujets. L'analyse de ces signaux, combinée à une discussion sur le ressenti du participant, permet d'évaluer la présence sexuelle et d'étudier sa manifestation physiologique. Le projet présenté dans ce mémoire s'inscrit dans la continuité directe des travaux menés à l'INPLPP par Brideau-Duquette et Saint-Pierre Côté, et repose sur l'analyse des données EEG recueillies dans le cadre de leurs expérimentations immersives.

Pour mesurer la réponse sexuelle, notre partenaire utilise la pléthysmographie qui mesure l'afflux sanguin au niveau de l'appareil génital. Les techniques utilisées pour effectuer cette mesure sont délicates à mettre en place et invasives pour les sujets.

L'intégration d'un scénario modulable dans les environnements virtuels est un projet en cours à l'INPLPP et présenterait un intérêt majeur pour les recherches en contexte médico-légal et clinique. En adaptant dynamiquement les stimuli en fonction des réponses physiologiques du sujet, il devient possible de personnaliser l'expérience immersive et d'optimiser la sensibilité des mesures. Cette flexibilité permet non seulement de maintenir l'engagement du participant, mais aussi de cibler plus précisément les zones d'intérêt diagnostique, en ajustant le contenu en temps réel selon les réactions cérébrales ou comportementales observées. Un scénario modulable permet de maximiser la pertinence des données recueillies pour l'analyse de l'intensité de la présence sexuelle.

Dans ce sens, le projet de recherche ici présenté se concentre sur deux objectifs :

- la prédiction de la réponse sexuelle, à partir de l'analyse des seuls signaux EEG, afin de supprimer la mesure de PPG invasive.

- la mise en place d'une chaîne de prédiction adaptable à un traitement en flux continu des données pour permettre une prédiction en temps réel de la réponse sexuelle dans le but de la future mise en place d'un outil permettant de personnaliser l'évolution du scénario immersif.

La suite du mémoire sera structurée de la manière suivante. Tout d'abord, au travers de la revue de littérature du chapitre 2, nous présenterons les travaux existants qui permettront de mieux définir nos objectifs et hypothèses de recherche dans le chapitre 3. Ensuite, le chapitre 4 décrit la mise en place de ces diverses méthodes, ainsi que l'établissement d'un protocole d'évaluation qui permettra de mettre en lumière leur efficacité. Les expérimentations et les résultats obtenus seront alors exposés et discutés dans le chapitre 5. Puis, le chapitre 6 mettra en avant les contraintes et limites de nos méthodes ainsi que des résolutions potentielles qui restent à explorer dans le futur. Nous reviendrons sur les résultats obtenus, leurs limitations et les pistes d'améliorations futures dans la conclusion au chapitre 7

CHAPITRE 2 REVUE DE CONNAISSANCES ET DE LA LITTÉRATURE

Préambule

Cette revue de littérature a pour objectif d'explorer différentes méthodes qui permettraient de mettre en place un outil de détection en temps réel de la présence sexuelle. Nous commencerons par étudier les fondements théoriques et les approches méthodologiques liées à la détection de la présence sexuelle à partir de signaux physiologiques notamment électroencéphalographiques (EEG).

Puis, afin d'élargir les perspectives méthodologiques de notre étude, nous examinerons les travaux issus de domaines connexes, en particulier celui de la reconnaissance d'émotions. Cette étude de méthodes issues de domaines connexes a pour but d'identifier des modèles transférables à notre projet et permettant d'anticiper les défis liés à la détection en temps réel, la variabilité inter-sujets et à la complexité des signaux EEG.

2.1 Définition de la présence sexuelle

La présence sexuelle désigne une forme spécifique de présence, définie comme le sentiment subjectif d'être en interaction avec un agent sexuel dans un environnement et en particulier dans un environnement numérique immersif.

C'est un état psychologique subjectif qui implique une interaction dynamique entre les propriétés du stimulus, les attentes de l'individu et les mécanismes cérébraux sous-jacents à l'engagement affectif et sexuel.

Selon Renaud et al. [1], elle mobilise des processus cognitifs tels que l'attention dirigée, la reconnaissance d'intentionnalité et l'engagement émotionnel. Cette expérience ne dépend pas exclusivement de la réalité virtuelle, mais peut émerger à partir de contenus visuels synthétiques, comme le démontrent les travaux de Renaud et al. [3].

Les recherches de Renaud et al. [1, 3] suggèrent que la présence sexuelle constitue un phénomène neurocognitif mesurable physiologiquement. Ces résultats ont été confirmés plus récemment par les travaux de Brideau-Duquette et al. [4] et Côté et al. [5].

2.2 Détection physiologique de la présence sexuelle

Les études sur la présence sexuelle s'appuient sur des données multimodales combinant des signaux physiologiques tels que l'EEG, l'oculométrie, la PPG (vaginale ou pénienne). Ces données sont généralement collectées dans des environnements immersifs en réalité virtuelle (VR), où les participants sont exposés à des stimuli à contenu sexuel contrôlé. Les données sont annotées après un entretien avec le participant ou ce dernier répond à un questionnaire indiquant l'intensité de la présence sexuelle ressentie pendant l'immersion. Les prédictions sont effectuées sur des immersions relativement longues (entre 30 s et 2 min). [3,4]

2.2.1 Pléthysmographie génitale

La pléthysmographie génitale (PPG car nous parlons de pléthysmographie pénienne dans le cas des participants masculins) est une mesure physiologique qui permet de mesurer l'afflux sanguin au niveau des parties génitales.

Dans le cadre de notre projet, elle est utilisée pour mesurer la réponse sexuelle [1, 3–5].

Chez l'homme, cela consiste à placer une jauge au mercure autour de la tige pénienne, et l'étirement de la jauge entraîne un changement de voltage proportionnel à l'afflux sanguin [6]. Chez la femme, la technique consiste à insérer une sonde dans la vulve, sonde dans laquelle se trouvent deux diodes à infrarouge, une émettrice et une réceptrice. La réflexion infrarouge captée par la diode réceptrice quantifie l'engorgement sanguin des parois de la vulve et permet une mesure de l'excitation sexuelle [5, 7]. Ces techniques sont délicates à mettre en place et invasives pour les sujets.

La PPG permet d'identifier des patrons d'activation physiologique en réponse à des contenus érotiques, pouvant être corrélés à une expérience subjective de présence sexuelle. [1, 3] Cette mesure physiologique directe offre ainsi un complément aux données EEG dans l'évaluation multimodale de la présence sexuelle [5].

2.2.2 Électroencéphalographie

L'EEG est la mesure de l'activité électrique interne du cerveau. Elle est réalisée via la pose d'électrodes sur la boîte crânienne. La répartition des différentes électrodes est visible sur la figure 4.2.

L'EEG constitue un outil privilégié pour l'étude de la présence sexuelle, en permettant de mesurer les dynamiques cérébrales associées à des états de présence sexuelle subjectivement rapportés. [1, 3–5].

L'analyse électroencéphalographique dans le cadre de l'étude de la présence sexuelle repose sur l'extraction de plusieurs types de caractéristiques du signal.

Bandes de fréquences et régions pertinentes. Les bandes de fréquences EEG jouent un rôle central dans la détection des états affectifs et cognitifs. Selon Guevara et al. [8] chez des participantes en contexte de stimulation sexuelle, une suppression des rythmes alpha frontaux (8–12 Hz) et une augmentation de l'activité dans les bandes bêta (13–30 Hz) et gamma (>30 Hz) ont été observées, notamment dans les régions temporales et pariétales, traduisant une activation corticale liée à l'excitation sexuelle. En revanche pour Brideau-Duquette et al. [4], chez des participants masculins, c'est davantage l'activité des bandes de fréquences alpha et bêta dans les régions frontales qui contient l'information relative à la présence sexuelle. De même pour Saint-Pierre Coté et al. [5] ce sont des caractéristiques de la région frontale dans la bande de fréquence alpha qui sont étudiées sur des participantes femmes.

Prétraitement. Le prétraitement des données EEG inclut généralement :

- Un filtrage passe-bande (souvent entre 0.5 Hz et 45 Hz) pour éliminer les artefacts de basse fréquence et les interférences haute fréquence.
- La suppression des artefacts liés aux mouvements oculaires et musculaires via des techniques comme l'analyse en composantes indépendantes (ICA pour Independent Component Analysis) [4].

Caractéristiques entropiques. L'entropie est utilisée pour quantifier la complexité et l'imprévisibilité du signal EEG. Des mesures telles que l'entropie de Sample [4] permettent d'évaluer la dynamique du signal cérébral en réponse à des stimuli sexuels. Renaud et al. [3] ont introduit une mesure d'entropie croisée dynamique frontale pour capturer les corrélats neurophysiologiques de la présence sexuelle. Cette approche permet de détecter les variations synchrones entre régions cérébrales en lien avec l'exposition à des contenus sexuels synthétiques, révélant des patrons spécifiques d'activation frontale associés à l'expérience subjective de présence. Cette mesure est également utilisée par Brideau-Duquette et al. [4].

Asymétrie cérébrale. L'asymétrie EEG, notamment dans les régions frontales et pariétales, constitue un indicateur pertinent de la latéralisation des réponses émotionnelles. Des études récentes par Saint-Pierre Coté et al. [5] ont montré que des asymétries dans l'activité cérébrale peuvent être des marqueurs de l'intensité de la présence sexuelle ressentie.

2.3 Prédiction de la présence sexuelle

Les architectures de prédiction utilisées dans le domaine de la prédiction de présence sexuelle sont principalement basées sur l'apprentissage profond mais restent relativement simples. La plupart des modèles utilisés sont des MLP fusionnant plusieurs modalités (EEG, oculométrie, PPG) via des couches connectées.

La quantité limitée de participants réduit la taille du jeu de données disponible et doit être prise en compte dans le choix des architectures utilisées.

La majorité des études adoptent une approche hors-ligne, où les signaux sont enregistrés, prétraités et analysés a posteriori.

Limites. Il convient de souligner que le champ de l'analyse des signaux physiologiques, et en particulier de l'EEG, appliquée à l'étude de la présence sexuelle demeure relativement récent et encore limité dans la littérature scientifique. À ce jour, la majorité des travaux cités précédemment ont été réalisés par des chercheurs affiliés à l'INPLPP, institution à laquelle le présent projet est également rattaché. Afin d'élargir la compréhension des approches méthodologiques disponibles pour l'analyse des signaux EEG, il apparaît pertinent d'examiner les contributions issues de domaines connexes, tels que la reconnaissance d'émotions et la détection de pathologies et troubles d'ordres neurologiques.

2.4 Analyse de l'EEG pour la reconnaissance d'émotions et autres domaines connexes

2.4.1 Pourquoi regarder le domaine de reconnaissance d'émotions ?

Le domaine de la reconnaissance d'émotions par EEG constitue une source précieuse d'inspiration, notamment en raison de la proximité entre les mécanismes neurophysiologiques impliqués dans les états émotionnels et ceux mobilisés lors de l'expérience de présence sexuelle.

De plus, ce champ bénéficie d'un corpus scientifique particulièrement riche, avec plusieurs centaines de publications recensées dans les dernières années. Cette dynamique est soutenue par l'existence de bases de données publiques et largement utilisées telles que **DEAP**, **SEED**, **DREAMER** ou **SEED-IV**, qui facilitent la reproductibilité des travaux et la comparaison des modèles. Plusieurs revues de littérature, ont été publiées pour synthétiser les avancées dans ce domaine. [9]

Il est important de noter que la reconnaissance d'émotion, notamment sur la base de données **DEAP** se fait généralement sur des enregistrements plus courts (environ 6 s) [10]. Ce qui

rend les méthodes utilisées intéressantes pour d'éventuelles applications en temps réel.

Cette maturité méthodologique et la disponibilité de ressources partagées font de la reconnaissance d'émotions un terrain fertile pour le transfert de connaissances vers des domaines émergents comme la détection de la présence sexuelle.

2.4.2 Architectures utilisées pour la reconnaissance d'émotions

CNN Les réseaux de neurones convolutionnels CNN sont largement utilisés dans le traitement des signaux EEG pour la reconnaissance des émotions. Ils sont souvent utilisés sur des représentations spatiales du signal où des caractéristiques spectrales ou entropiques sont extraites du signal de chaque électrode puis combinées dans une représentation 2D exploitant les positions relatives des électrodes. Par exemple, Bashivan et al. [11] ont proposé un modèle CNN capable d'extraire des représentations spatio-temporelles robustes à partir des données EEG brutes. De même, Lawhern et al. [12] ont introduit **EEGNet**, une architecture légère et efficace pour la classification EEG. Ces approches ont démontré leur efficacité sur des bases comme **DEAP** et **SEED**, bien que leur capacité à capturer et modéliser les dépendances temporelles des signaux EEG reste limitée [9].

Réseaux de neurones récurrents (Recurrent Neural Network) (RNN) Les réseaux de neurones récurrents sont également souvent utilisés, notamment les architectures de type réseau à mémoire long-court terme (Long Short-Term Memory) (LSTM) et unité récurrente à barrière (Gated Recurrent Unit) (GRU), conçues pour modéliser les séquences temporelles. Zhang et al. [13] ont proposé un modèle STRNN (Spatial-Temporal RNN) qui exploite les dépendances spatiales et temporelles du signal EEG pour améliorer la reconnaissance émotionnelle. Ces modèles permettent de capturer les dynamiques cérébrales liées aux émotions, mais peuvent être sensibles au bruit et à la variabilité inter-sujets [9].

Architectures hybrides (CNN-RNN) Pour combiner les avantages des CNN et des RNN, plusieurs travaux ont proposé des architectures hybrides. Ramzan et Dawn [14] ont développé un modèle CNN-LSTM fusionné, appliqué aux bases **DEAP** et **SEED**, qui atteint des taux de précision élevés en intégrant les caractéristiques spatiales et temporelles du signal EEG. Ce type d'architecture permet une modélisation plus complète du signal, bien qu'il implique une grande complexité computationnelle et donc un nombre de données important [9].

RA-CNN Le modèle RA-CNN, proposé par Li et al. [15], est une architecture conçue pour la reconnaissance des émotions à partir de signaux EEG. Des caractéristiques profondes de chacun des signaux EEG sont extraites par réseaux convolutionnels. Les caractéristiques extraites de chaque électrode sont utilisées pour créer une représentation spatiale 2D sur laquelle ils utilisent deux CNN pour extraire des caractéristiques régionales et asymétriques. Cette approche permet une modélisation plus fine des dynamiques cérébrales liées aux émotions et semble améliorer la variabilité inter-sujets. Malheureusement ce modèle a une complexité architecturale accrue ce qui peut soulever des problèmes de surapprentissage si la taille de notre jeu de données est trop petite.

Transformers Les modèles Transformers ont été adaptés à l'analyse des signaux EEG. Liu et al. [16] ont proposé le modèle EEG émotion Transformer (EeT), basé sur des blocs d'attention spatiale et temporelle, permettant une extraction conjointe des caractéristiques spectrales, spatiales et temporelles. Ces modèles surmontent les limitations des CNN et RNN en capturant des dépendances globales sans contraintes séquentielles. Bien que les résultats soient prometteurs, l'entraînement de ces réseaux nécessite de très grandes quantités de données [9].

2.4.3 Architectures utilisées dans d'autres domaines

Parmi les nombreuses méthodes présentes dans le domaine de la reconnaissance d'émotions, l'application directe de CNN aux spectrogrammes EEG reste étonnamment rare. Les spectrogrammes peuvent entraîner une perte de résolution temporelle, ce qui limite leur capacité à représenter les dynamiques émotionnelles fines.

Cependant, dans le cadre de notre projet, l'utilisation de CNN sur des spectrogrammes EEG présente un intérêt particulier. Cette approche a montré son efficacité pour détecter des patrons pathologiques dans des signaux EEG complexes. Par exemple, Esquivel et al. [17] ont utilisé des spectrogrammes transformés par ondelettes comme entrée dans un CNN pour détecter des crises d'épilepsie avec une précision élevée. De même, Thomas et al. [18] ont démontré que des CNN appliqués à des spectrogrammes EEG permettent une classification automatique des stades du sommeil et la détection de troubles associés. Ces résultats suggèrent que les spectrogrammes EEG, combinés à des architectures CNN bien calibrées, pourraient offrir une voie prometteuse pour la détection de la présence sexuelle, notamment en capturant des signatures neurophysiologiques complexes.

CHAPITRE 3 OBJECTIFS DE RECHERCHE

Le but de ce projet est la mise en place d'un outil d'apprentissage automatique utilisable dans le cadre de la modularisation d'un scénario immersif VR et basé sur des enregistrements physiologiques acquis de manière non-invasive.

Synthèse de la revue de littérature À la suite de cette revue de littérature, nous pouvons observer les faits suivants :

- Les travaux de l'INPLPP étudient la présence sexuelle qui est un état subjectif et se basent sur l'étude à posteriori de segments d'enregistrements longs et nécessitent l'utilisation de la mesure PPG invasive.
- La présence sexuelle ne peut être réduite à une réponse immédiate. En effet, elle est définie comme une expérience subjective d'engagement affectif et cognitif envers un agent sexuel dans un environnement médiatisé. C'est une mesure subjective, mobilisant des processus attentionnels, émotionnels et représentationnels. Elle suppose une forme de co-présence perçue avec un partenaire virtuel ou synthétique, et s'inscrit dans une temporalité plus étendue. On s'intéressera dans le cadre de ce projet à la réponse physiologique rapide et automatique à un stimulus sexuel, ce que l'on peut appeler une impulsion sexuelle.
- Le domaine de la reconnaissance d'émotions a développé des méthodes computationnelles adaptées à l'analyse de signaux EEG.
- La reconnaissance d'émotion se fait sur de très larges bases de données, souvent publiques et les architectures les plus efficaces (transformers, CNN-RNN) sont assez lourdes.
- Les architectures CNN par analyse de spectrogrammes n'ont, à notre connaissance, pas été utilisées dans ce domaine et présentent un intérêt potentiel.

Objectifs du projet Il n'existe pas, à notre connaissance un outil computationnel permettant la détection de l'impulsion sexuelle sur la seule analyse de l'EEG. C'est ce que nous souhaitons mettre en place dans ce projet. Notre outil doit satisfaire les contraintes suivantes :

- Être capable de détecter automatiquement une réponse physiologique à un stimulus sexuel via l'analyse de données EEG. Afin de pouvoir se passer de l'enregistrement invasif de la PPG.
- Être adapté ou adaptable à un traitement des données en flux continu pour une future utilisation en temps réel. Donc basé sur des segments de données plus courts.

- Être généralisable à des participants inconnus (résistant à la très forte variabilité intersujets de l'EEG) ou, le cas échéant, pouvoir se raffiner facilement pour être performant sur des participants dont on ne connaît qu'une quantité limitée de données (données de calibration).

Pour cela, nous testerons diverses méthodes et architectures d'apprentissage automatique afin d'établir lesquelles sont les plus adaptées.

Nous nous baserons sur les hypothèses suivantes :

- Les caractéristiques de l'EEG utilisées dans le domaine de la détection de présence sexuelle (étude des bandes de fréquences alpha et bêta dans la région frontale, calcul de caractéristiques entropiques, ...) sont utilisables dans le cadre de la détection de l'impulsion sexuelle.
- Les méthodes d'apprentissage automatique issues de la reconnaissance d'émotions ou d'autres domaines connexes sont transférables à ce projet mais doivent être adaptées aux conditions et contraintes spécifiques.

CHAPITRE 4 MÉTHODES ET EXPÉRIENCES

4.1 Données disponibles et Prétraitement

Les données avec lesquelles nous travaillons ont été collectées par Sarah Saint-Pierre Coté et Matthieu Brideau-Duquette [4] [5], dans le cadre d'un projet plus large de l'institut Philippe Pinel 1.

4.1.1 Explication des conditions expérimentales

Participants et scénarios

Nous avons accès à des données obtenues à partir de 30 participants volontaires cisgenres hétérosexuels masculins âgés de 20 à 35 ans. Chaque participant a été immergé dans quatre scénarios de réalité virtuelle différents.

- Diffusion d'une vidéo neutre **VidNeutre** dans laquelle il n'y a aucune stimulation sexuelle.
- Diffusion d'une vidéo "sexuelle" **VidSex** contenant du contenu pornographique/érotique afin d'éveiller une stimulation sexuelle.
- Diffusion d'un scénario en réalité virtuelle (VR) neutre en 3D généré **VidAndroïde** dans lequel les participants interagissent pour la première fois avec un personnage virtuel personnalisé qu'ils ont créé avant l'expérience. Ce scénario ne contient aucune stimulation sexuelle. Les interactions avec le personnage sont asexuelles.
- Diffusion d'un scénario sexuel en VR en 3D généré **VidPVP-EVP** où le personnage virtuel a un comportement sexuellement explicite afin d'éveiller une stimulation sexuelle.

Signaux physiologiques enregistrés

Durant l'immersion dans les quatre scénarios, les données physiologiques suivantes ont été enregistrées [4] :

La **tumescence pénienne** a été mesurée à l'aide de la PPG. Les données de la PPG ont été enregistrées avec le logiciel DataPac et traitées à l'aide de la suite logicielle PrefTest Professional (version 11.3.0.20 ; tous produits par Limestone Technologies).

Les enregistrements **EEG** ont été réalisés à l'aide d'un bonnet équipé de 32 électrodes actives, selon le système 10–20 (Acticap, Brain Vision). Le signal EEG a été amplifié en temps réel à l'aide de l'amplificateur ActiChamp de Brain Vision, puis enregistré à l'aide des logiciels

MOVE et Recorder de Brain Vision (version 1.20.0401).

Selon [4], les données des électrodes frontales FP1, FP2, F7, F3, Fz, F4, F8, FC5, FC1, FC2, FC6 semblent les plus pertinentes pour la reconnaissance de la présence sexuelle et donc de l'impulsion sexuelle, nous ne conserverons donc que les données de ces 11 électrodes.

Filtrage et échantillonnage

Les mesures PPG sont échantillonnées à 25 Hz et ne subissent aucun filtrage.

Les mesures EEG sont échantillonnées à 500 Hz. Le signal a ensuite été immédiatement soumis à un filtrage, incluant un filtre passe-bas réglé à 1,59 Hz, un filtre passe-haut réglé à 70 Hz, ainsi qu'un filtre coupe-bande à 60 Hz destiné à atténuer le bruit électrique ambiant propre aux installations nord-américaines. Dans le cadre de notre étude nous nous intéressons uniquement aux bandes de fréquences *delta*, *theta*, *alpha* et *beta* (comprises des fréquences de 0.5 à 25 Hz) donc nous effectuons un deuxième filtrage passe-bas à 30 Hz et, pour réduire la taille des données, un ré-échantillonnage à 60 Hz.

4.1.2 Formatage pour une utilisation en temps réel et étiquetage

Formatage pour une prédiction en temps réel

Afin de pouvoir être adapté à une utilisation en temps réel, nous souhaitons effectuer une prédiction de l'impulsion sexuelle sur une courte période de temps. À partir de chacun de nos signaux, nous extrayons un point de données par seconde à l'instant t , en conservant les 6 secondes précédentes d'EEG comprises entre $t - 6s$ et t pour $t \geq 6s$.

Les points de données correspondent à des fenêtres de 6 secondes contenant 360 échantillons par électrode avec un recouvrement temporel de 5 secondes, soit un taux de 83%.

Étiquetage des données

Pour créer nos bases de données, nous cherchons à déterminer quelles parties de quels scénarios correspondent à des états excités, présentant une impulsion sexuelle ou à des états neutres. Pour effectuer cet étiquetage, nous regardons les courbes de PPG des patients dans chacun des scénarios avec l'aide d'un expert dans le domaine : Dr Patrice Renaud.

Seules les courbes PPG de l'immersion dans des scénarios vidéo et non générés en 3D sont suffisamment claires pour procéder à un étiquetage certain.

Dans le cadre de l'immersion en scénario vidéo à caractère sexuel, nous définissons une plage

temporelle correspondant à un pic et au plateau du maximum de la PPG qui témoigne d'une impulsion sexuelle. Nous définissons toutes les données dont l'horodatage est dans cet intervalle comme correspondant à un état excité.

Au vu de la PPG seule, il est difficile de dire si le reste du scénario présente un état d'impulsion sexuelle, les données dont l'horodatage est en dehors de ces plages ne sont donc pas étiquetées et ne seront pas prises en compte dans l'entraînement des modèles.

Nous prenons donc l'ensemble des données recueillies dans le cadre du scénario vidéo neutre **VidNeutre** comme correspondant à un état neutre non-excité.

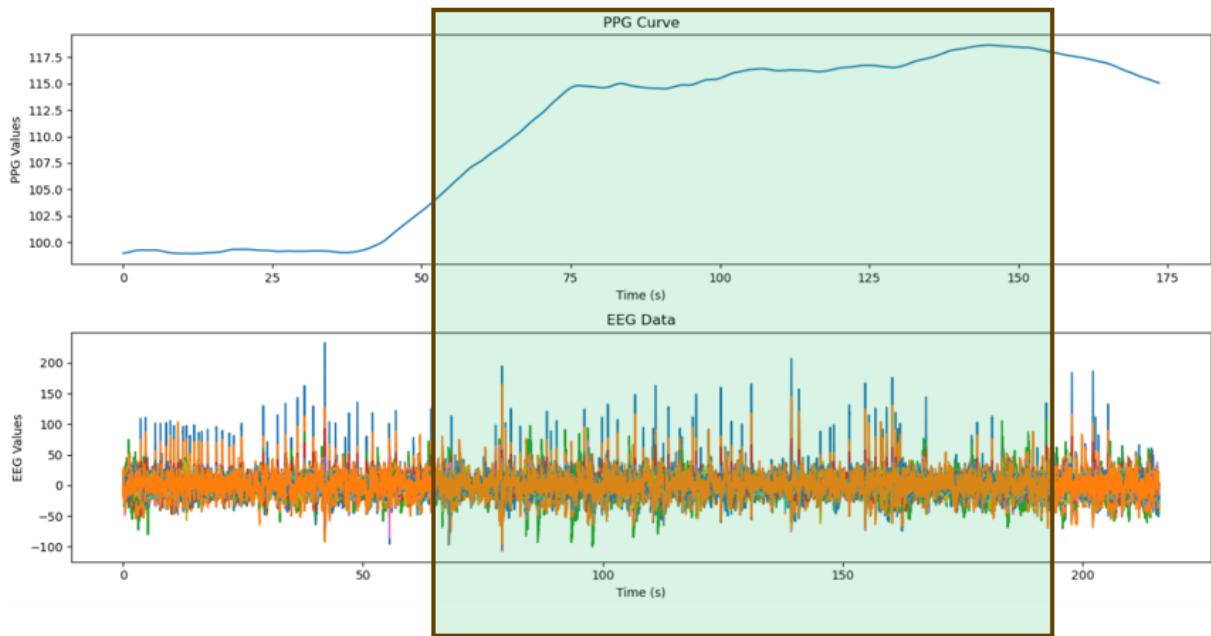


FIGURE 4.1 En vert, intervalle des instants correspondant à un état excité pour le scénario **VidSex** pour un participant.

4.1.3 Prétraitement par analyse par composantes indépendantes

Nous disposons de ces données EEG "brutes" ainsi que des données EEG pré-traitées également obtenues dans le cadre des travaux précédents [4, 5]. Ces données ont été traitées à l'aide du logiciel Analyzer 2.1 (Brain Vision), dans lequel les canaux trop bruités ont été identifiés et exclus lors d'inspections visuelles. Une analyse en composantes indépendantes ICA a ensuite été appliquée en utilisant l'algorithme de pente moyenne, des ensembles de données spécifiques aux conditions, ainsi que les méthodes Infomax et de somme des corré-

lations quadratiques issues du logiciel Analyzer, afin d'éliminer les composantes de bruit les plus importantes majoritairement associées aux mouvements oculaires.

Le même filtrage passe-bas à 30 Hz et ré-échantillonnage à 60 Hz ainsi que le processus d'extraction/étiquetage défini plus haut ont été appliqués à ces données pré-traitées.

Il est cependant important de noter que ce prétraitement nécessite une connaissance du signal dans son ensemble. Le but de notre recherche est d'effectuer une prévision de l'impulsion sexuelle en temps-réel donc de traiter les données entrantes comme un flot, ce qui rendrait l'utilisation de ce prétraitement incompatible avec la mise en place de futures expériences en temps réel.

4.2 Classification par analyse de spectrogrammes

Notre première approche consiste à examiner la représentation de la densité spectrale de puissance dans les domaines fréquentiel et temporel, en utilisant une représentation par spectrogramme, puis à analyser ces spectrogrammes à l'aide de réseaux de neurones convolutifs (CNN). Bien que peu commune dans le domaine de la reconnaissance d'émotions, l'étude de l'EEG par analyse spectrographique est utilisée en médecine pour détecter diverses pathologies comme l'épilepsie [17] et certains troubles du sommeil [18].

4.2.1 Extraction de spectrogrammes

Chaque point de données de 6 secondes échantillonné à 60 Hz contient 360 échantillons pour chacune des 11 électrodes frontales. Pour chaque signal, un spectrogramme de densité spectrale linéaire est extrait à l'aide de la fonction `matplotlib.pyplot.specgram` de la bibliothèque Matplotlib. Cette extraction est réalisée sans suppression de la tendance linéaire du signal avec 64 échantillons par segment spectral, un recouvrement de 32 échantillons, et l'application d'une fenêtre de Hamming sur chacun des segments. Nous obtenons ainsi un spectrogramme de dimension 33x10 évaluant la densité spectrale de fréquences de 0 à 30 Hz.

Les spectrogrammes ainsi obtenus sont combinés dans une image multicanal de dimension 33x10x11.

4.2.2 Architectures CNN pour analyse de spectrogrammes

Nous utilisons ici des architectures CNNs très minimalistes. Au vu de la taille très limitée du jeu de données, un réseau avec trop de paramètres risque de surapprendre. Nous utilisons trois architectures `SpectroCNN_3` décrits en 4.1, avec des noyaux 3×3 , `SpectroCNN_5` décrits

en 4.2 avec des noyaux 5×5 et **SpectroCNN_Res** décris en 4.3 avec plusieurs tailles de noyaux et une connexion résiduelle.

TABLEAU 4.1 Architecture du modèle **SpectroCNN_3** avec nombre de paramètres

Type de couche	Taille de sortie	Nb paramètres
Entrée	$11 \times 33 \times 10$	-
Convolution 3×3 , padding=0 (11→32)	$32 \times 31 \times 8$	3 200
BatchNorm	$32 \times 31 \times 8$	64
ReLU	$32 \times 31 \times 8$	-
Convolution 3×3 , padding=0 (32→64)	$64 \times 29 \times 6$	18 496
BatchNorm	$64 \times 29 \times 6$	128
ReLU	$64 \times 29 \times 6$	-
Convolution 3×3 , padding=1 (64→64)	$64 \times 29 \times 6$	36 928
ReLU	$64 \times 29 \times 6$	-
Convolution 3×3 , padding=1 (64→64)	$64 \times 29 \times 6$	36 928
ReLU	$64 \times 29 \times 6$	-
Flatten	5568	-
Dense (64 unités)	64	356 416
Dropout ($p = 0,3$)	64	-
Dense (1 unité)	1	65
Activation Sigmoid	1	-
Total	—	452 225

Tous ces modèles utilisent des activations RELU entre chaque convolution et une couche SIGMOID avant la sortie. Pour éviter le surapprentissage, nous ajoutons dans tous les modèles deux couches de normalisation par lot (**BatchNorm**) après les premières convolutions et une couche de désactivation aléatoire (**Dropout**) avec une probabilité de désactivation de **p=0.3** avant la dernière couche dense.

Une recherche d'optimisation des hyperparamètres par grille a montré que les meilleurs résultats étaient obtenus avec une taille de batch de **100**, un taux d'apprentissage initial de **0.0001** pour 150 epochs.

Nous utilisons ici une fonction de perte d'entropie croisée binaire et un optimiseur de type **ADAM**.

TABLEAU 4.2 Architecture du modèle SpectroCNN_5 avec nombre de paramètres

Type de couche	Taille de sortie	Nb paramètres
Entrée	$11 \times 33 \times 10$	-
Convolution 5×5 , padding=0 (11→32)	$32 \times 29 \times 6$	8 832
BatchNorm	$32 \times 29 \times 6$	64
ReLU	$32 \times 29 \times 6$	-
Convolution 5×5 , padding=2 (32→64)	$64 \times 29 \times 6$	51 264
BatchNorm	$64 \times 29 \times 6$	128
ReLU	$64 \times 29 \times 6$	-
Convolution 5×5 , padding=2 (64→64)	$64 \times 29 \times 6$	102 464
ReLU	$64 \times 29 \times 6$	-
Convolution 5×5 , padding=2 (64→64)	$64 \times 29 \times 6$	102 464
ReLU	$64 \times 29 \times 6$	-
Flatten	5568	-
Dense (64 unités)	64	356 416
Dropout ($p = 0,3$)	64	-
Dense (1 unité)	1	65
Activation Sigmoid	1	-
Total	—	622 697

4.3 Classification par extraction de caractéristiques temporelles profondes

La seconde approche est inspirée directement du domaine de la reconnaissance d’émotions [15]. Nous analysons l’EEG en extrayant des caractéristiques profondes par convolutions sur l’axe temporel pour chacune des électrodes et nous allons ensuite comparer les caractéristiques de chacune des électrodes avec les électrodes voisines (caractéristiques régionales) et les électrodes opposées (caractéristiques asymétriques).

4.3.1 Représentation spatiale de l’EEG

Pour pouvoir extraire ces caractéristiques spatiales des signaux EEG, nous assignons à chacune de nos électrodes un pixel d’une image en s’aidant de la vue en plan du système international 10-20 comme dans la figure 4.2. Nous n’utilisons que les électrodes frontales, FP1, FP2, F7, F3, Fz, F4, F8, FC5, FC1, FC2, FC6 que l’on assigne à l’image 4×9 schématisée dans le Tableau 4.4.

Nous transformons donc notre vecteur de données 11×360 en matrice de données $4 \times 9 \times 360$. Les données des pixels non-associés à des électrodes peuvent être interpolées (de manière gaussienne ou linéaire) mais de telles méthodes introduisent du bruit et augmentent la charge computationnelle. Nous mettons donc des valeurs nulles pour ces positions.

TABLEAU 4.3 Architecture du modèle SpectroCNN_Res avec nombre de paramètres

Type de couche	Taille de sortie	Nb paramètres
Entrée	$11 \times 33 \times 10$	-
Convolution 5×5 , padding=0 (11→32)	$32 \times 29 \times 6$	8 832
BatchNorm	$32 \times 29 \times 6$	64
ReLU	$32 \times 29 \times 6$	-
Convolution 3×3 , padding=1 (32→64)	$64 \times 29 \times 6$	18 496
BatchNorm	$64 \times 29 \times 6$	128
ReLU	$64 \times 29 \times 6$	-
<i>Sauvegarde pour addition résiduelle</i>	-	-
Convolution 3×3 , padding=1 (64→64)	$64 \times 29 \times 6$	36 928
ReLU	$64 \times 29 \times 6$	-
Convolution 3×3 , padding=1 (64→64)	$64 \times 29 \times 6$	36 928
Addition résiduelle + ReLU	$64 \times 29 \times 6$	-
Flatten	5568	-
Dense (64 unités)	64	356 416
ReLU	64	-
Dropout ($p = 0,3$)	64	-
Dense (1 unité)	1	65
Activation Sigmoid	1	-
Total	—	457 857

4.3.2 Extraction de caractéristiques par convolutions sur l'axe temporel

Pour ce modèle, nous proposons d'utiliser des couches de convolution unidimensionnelles continues afin d'extraire séparément les caractéristiques temporelles de chaque canal EEG. L'architecture est illustrée à la Figure 4.3. Les opérations de convolution sont effectuées uniquement dans la dimension temporelle. Quatre couches de convolution successives, contenant respectivement 4, 8, 16 et 32 noyaux temporels, sont appliquées dans cette étape.

La taille des noyaux est définie comme suit pour les quatre couches respectivement : 16, 5, 5, 12. Les convolutions sont réalisées avec un stride de 3 et sans padding, ce qui réduit la taille de l'axe temporel de 360 à 1.

Cette implémentation diffère du modèle original conçu pour la reconnaissance des émotions, [19] qui commençait avec des noyaux de petite taille afin de capturer des caractéristiques de plus haute fréquence. À l'inverse, notre approche commence par un noyau plus large, suivi de noyaux plus petits, et se termine par une dernière convolution dont le noyau couvre toute la longueur de l'entrée temporelle — ce qui équivaut fonctionnellement, à une couche dense sur l'axe temporel, mais permet une implémentation plus simple.

Le tenseur résultant f_T appartient à $\mathbb{R}^{4 \times 9 \times 32}$, représente une carte de caractéristiques tempo-

0	0	0	FP1	0	FP2	0	0	0
0	0	0	0	0	0	0	0	0
F7	0	F3	0	Fz	0	F4	0	F8
0	FC5	0	FC1	0	FC2	0	FC6	0

TABLEAU 4.4 Positionnement spatial des électrodes frontales dans une matrice 4x9

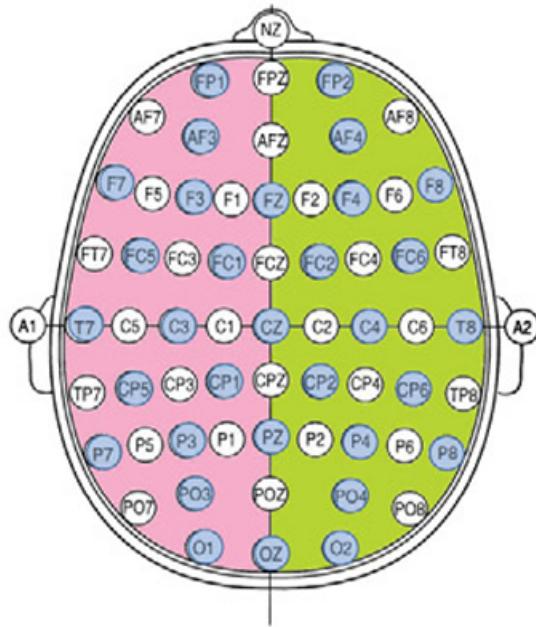


FIGURE 4.2 Répartition spatiale des électrodes EEG.

relles par électrode, projetée sur une grille de taille 4×9 avec 32 canaux de sortie. Chacune de ces convolutions est suivie d'une couche d'activation RELU.

4.3.3 Extraction de caractéristiques régionales avec un CNN

Les caractéristiques temporelles préalablement obtenues peuvent être considérées comme des images en couleur : les deux premières dimensions représentant la hauteur et la largeur, et la dernière dimension étant analogue à un canal de couleur.

Dans les tâches de classification d'images, les réseaux de neurones convolutifs (CNN) s'avèrent particulièrement efficaces pour extraire des représentations locales, grâce à leurs champs récepteurs restreints. Notre objectif ici est de capturer l'information spatiale entre électrodes

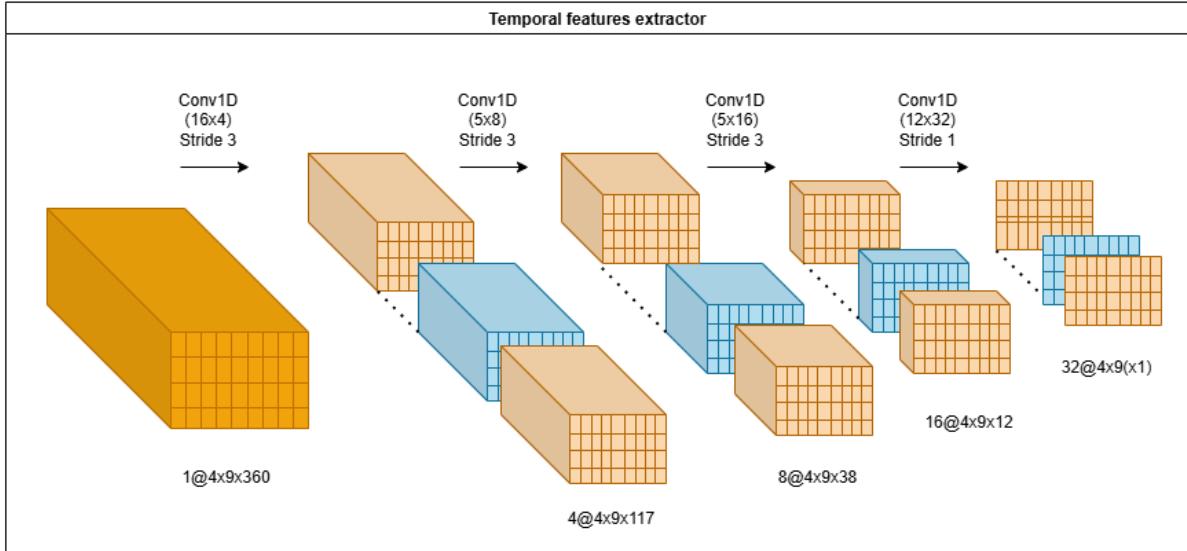


FIGURE 4.3 Extraction de caractéristiques profondes sur l'axe temporel.

adjacentes. Pour cela, trois couches de convolution bidimensionnelles de taille 3×3 sont appliquées successivement, chacune comportant 32 filtres. Un remplissage par zéros (zero-padding) est utilisé à chaque étape afin de préserver les informations en bordure des cartes de caractéristiques temporelles. À l'issue de ces trois couches convolutives, les caractéristiques régionales sont extraites. $f_R \in \mathbb{R}^{4 \times 9 \times 32}$ Chacune de ces convolutions est suivie d'une couche d'activation RELU.

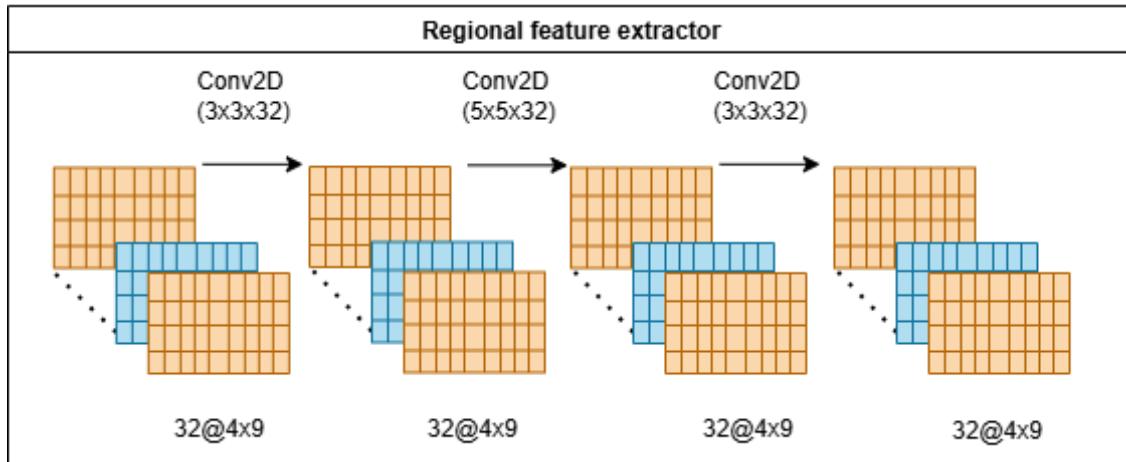


FIGURE 4.4 Extraction de caractéristiques régionales de haut niveau.

4.3.4 Extraction de caractéristiques asymétriques

Des études en neurosciences ont montré que les réponses de présence sexuelle présentent une asymétrie frontale entre les hémisphères gauche et droit du cerveau [5]. Bien que l'opération de convolution utilisée dans l'extracteur régional de caractéristiques permette de capturer des relations spatiales locales, elle ne permet pas d'extraire des informations à longue distance, notamment entre des positions symétriques sur le crâne.

Afin de mieux modéliser ces différences asymétriques entre les deux hémisphères, nous utilisons un mécanisme appelé couche de différence asymétrique (ADL), qui effectue une soustraction entre les canaux appariés correspondant à des positions symétriques. Notons $f_T \in \mathbb{R}^{h \times w \times 32}$ les caractéristiques temporelles extraites, l'ADL est alors formulé comme suit :

$$\tilde{f}_A(i, j, k) = f_T(i, j, k) - f_T(i, w + 1 - j, k), i \in [|1, 4|], j \in [|1, \left\lfloor \frac{9}{2} \right\rfloor |], k \in [|1, 32|] \quad (4.1)$$

Le tenseur $\tilde{f}_A \in \mathbb{R}^{4 \times \left\lfloor \frac{9}{2} \right\rfloor \times 32}$ représente les caractéristiques asymétriques préliminaires.

Pour extraire des caractéristiques asymétriques de niveau supérieur, nous appliquons une couche de convolution de taille 1×1 sur \tilde{f}_A . Cette opération permet d'intégrer les différences asymétriques au sein de chaque paire de canaux. Afin de conserver un nombre d'éléments de sortie cohérent avec celui de f_R , le nombre de filtres est fixé à 64, ce qui donne $f_A \in \mathbb{R}^{h \times \left\lfloor \frac{w}{2} \right\rfloor \times 64}$. Cette convolution est suivie d'une couche d'activation RELU.

Cette extraction de caractéristiques asymétriques est illustrée à la Figure 4.5.

4.3.5 Architecture du réseau convolutif régional asymétrique (RA-CNN)

À la suite de l'extraction des caractéristiques régionales f_R et asymétriques f_A , celles-ci sont d'abord aplatis en vecteurs, puis concaténées pour former un vecteur unique de représentation globale. Ce vecteur est ensuite transmis à une séquence de deux couches entièrement connectées, suivie d'une couche de régularisation par désactivation aléatoire (**Dropout**), puis d'une dernière couche dense de classification. Ce processus peut être formulé comme suit : $\mathbf{o} = FC(f_R \parallel f_A)$. Toutes les couches de notre réseau sont suivies d'une activation RELU et la dernière couche d'une activation SIGMOÏDE.

L'architecture complète est illustrée à la Figure 4.6.

Une recherche d'optimisation des hyperparamètres par grille a montré que les meilleurs résultats sont obtenus avec une taille de batch de **200**, un taux d'apprentissage initial de **0.0001** pour 150 itérations.

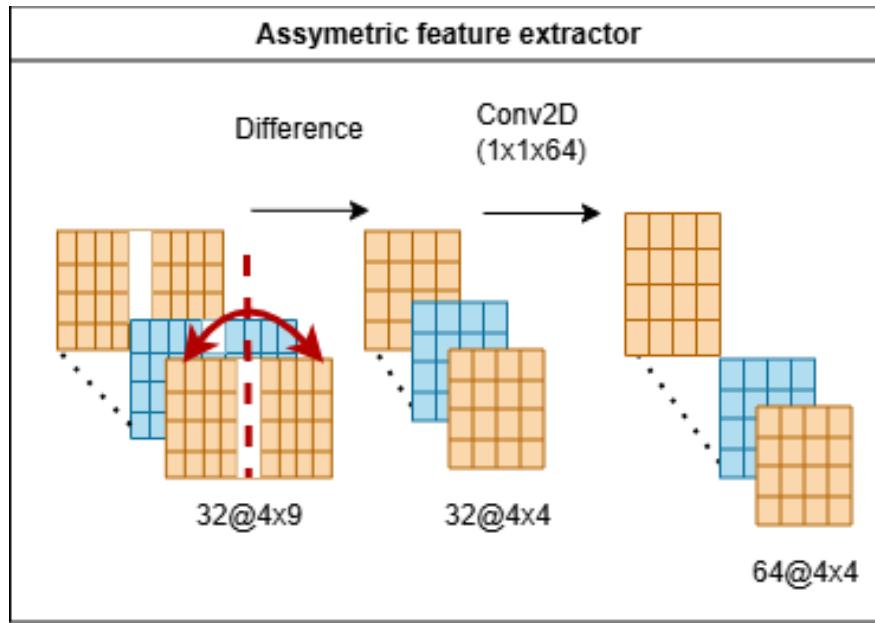


FIGURE 4.5 Extraction de caractéristiques asymétriques de haut niveau.

Nous utilisons ici une perte entropie croisée binaire et un optimiseur ADAM.

Nous testons l'importance des caractéristiques temporelles et régionales en entraînant deux modèles similaires R_CNN et A_CNN qui n'utilisent respectivement que les caractéristiques régionales et que les caractéristiques asymétriques.

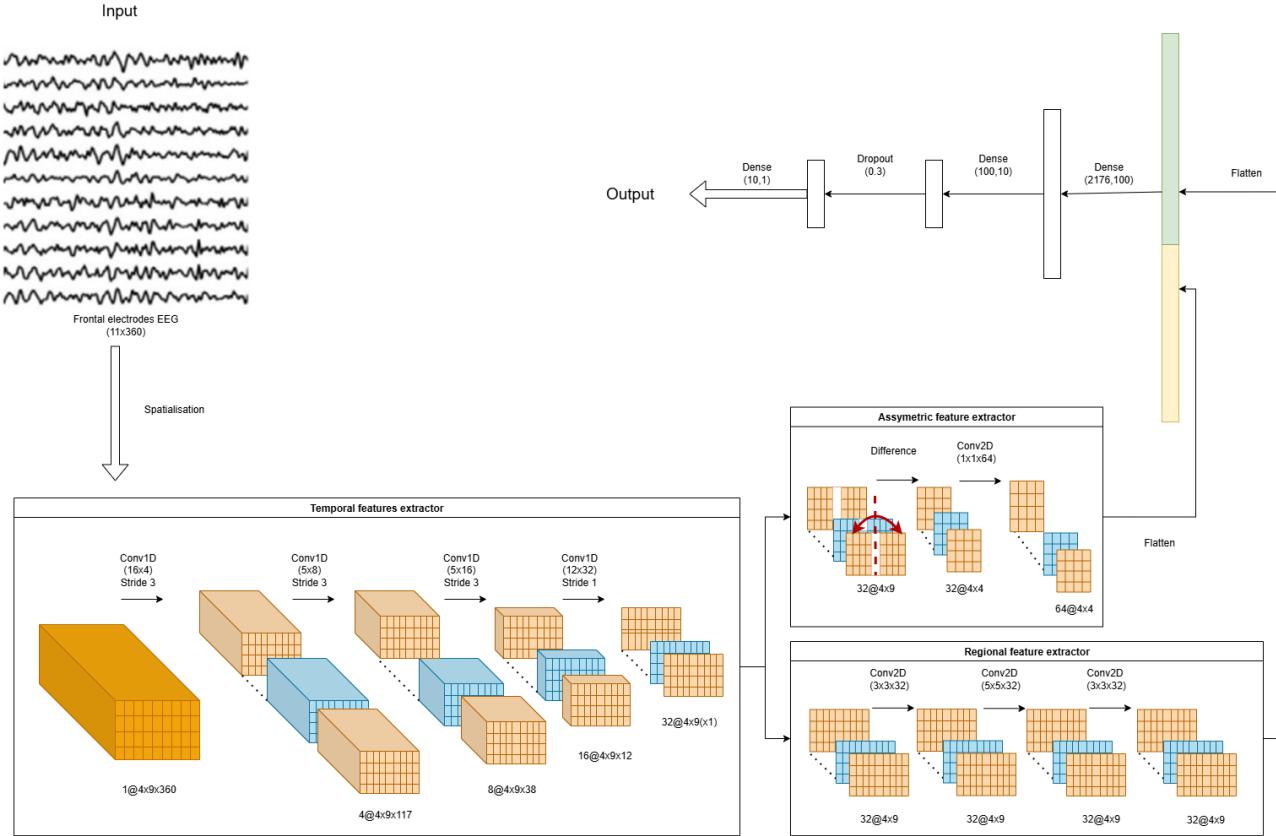


FIGURE 4.6 Architecture complète du réseau RA_CNN.

4.4 Classifications par analyses de caractéristiques entropiques

Des articles récents en détection de présence sexuelle utilisent la mesure d'entropie croisée dynamique (DCE) de différentes bandes de fréquences [4] [5]. Nous cherchons à mettre en place des modèles de classification basés sur cette caractéristique mais aussi sur les valeurs des entropies des différentes bandes de fréquence de chaque électrode.

4.4.1 Extraction de caractéristiques entropiques

Séparation des données en bandes de fréquences

Avant d'extraire l'entropie de nos signaux, nous voulons diviser le signal en quatre bandes de fréquences *alpha basse* de 8 à 10,5 Hz, la bande *alpha haute* de 10,5 à 13 Hz, la bande *beta basse* de 13 à 20 Hz, et la bande *beta haute* de 20 à 30 Hz.

Pour cela, le signal est d'abord normalisé en fonction de la fréquence de Nyquist, puis un

filtre de Butterworth d'ordre 4 est conçu pour cibler la bande de fréquences souhaitée. Ce filtre est ensuite appliqué au signal original à l'aide d'un filtrage avant-arrière sans déphasage (`filtfilt`), garantissant une réponse en phase linéaire. Ce traitement permet d'atténuer les artefacts hors bande tout en conservant fidèlement la structure temporelle du signal.

Nous explorons également un découpage alternatif sur les bandes de fréquences *delta* de 0,5 à 4 Hz, *thêta* de 4 à 8 Hz, *alpha* de 8 à 13 Hz et *bêta* de 13 à 25 Hz.

Qu'est-ce que l'entropie ?

L'entropie évalue la complexité temporelle d'un signal en mesurant la dispersion et la redondance de motifs.

Pour mieux comprendre ce que représente ces caractéristiques entropiques, nous considérons un signal $x = x_0, x_1, \dots, x_N$ de longueur N et une dimension d'intégration m .

Pour cela, nous construisons les vecteurs d'intégration $A^{(m)}(x)$ et $A^{(m+1)}(x)$ comme suit :

$$A^{(m)}(x) = A_1^{(m)}, \dots, A_{N-m+1}^{(m)} \text{ où } A_i^{(m)} = [x_i, \dots, x_{i+m-1}] \quad (4.2)$$

Nous utilisons ces vecteurs d'intégration pour construire des vecteurs de distances $D^{(m)}(x)$ et $D^{(m+1)}(x)$ obtenus en aplatisant les matrices de distances $\tilde{D}^{(m)}(x)$ et $\tilde{D}^{(m+1)}$ définies comme suit :

$$\tilde{D}^{(m)}(x)_{i < j} = \|A_j^{(m)}, A_i^{(m)}\|_2 = \sqrt{(A_i^{(m)} - A_j^{(m)})^2} \quad (4.3)$$

Pour extraire les caractéristiques entropiques de chacun de nos signaux filtrés, nous utilisons la librairie EntropyHub sur Python. [20]

Entropies "Sample" et "Fuzzy"

L'entropie par échantillon, dite Sample, consiste à seuiller les vecteurs de distance par rapport à un seuil r et à l'écart type du signal σ pour obtenir les vecteurs binaires $B^{(m)}(x, r)$ et $B^{(m+1)}(x, r)$ selon :

$$B_k^{(m)}(x, r) = \begin{cases} 1, & \text{si } D_k^{(m)}(x) > r \cdot \sigma \\ 0, & \text{sinon} \end{cases} \quad \text{pour } k = 1, 2, \dots, N \quad (4.4)$$

La valeur de l'entropie Sample est ensuite calculée de la façon suivante :

$$\text{SampleEn}(x, m, r, N) = -\ln \left(\frac{\sum B_k^{(m+1)}(x, r)}{\sum B_k^{(m)}(x, r)} \right) \quad (4.5)$$

L'entropie floue, dite Fuzzy, est basée sur une modélisation probabiliste de la distance de chaque motif à tous les autres, elle passe par le calcul de $P^{(m)}(x, r)$ et $P^{(m+1)}(x, r)$ avec :

$$P_i^{(m)}(x, r) = \frac{1}{N-m} \sum_{j=1, j \neq i}^{N-m} e^{-\ln(2) \left(\frac{\bar{D}_{i,j}^{(m)}(x)}{r} \right)^2} \quad (4.6)$$

Puis nous obtenons l'équation de l'entropie Fuzzy de façon similaire.

$$\text{FuzzyEn}(x, m, r, N) = -\ln \left(\frac{\sum P_k^{(m+1)}(x, r)}{\sum P_k^{(m)}(x, r)} \right) \quad (4.7)$$

. Nous calculons ces deux entropies pour chacun des signaux filtrés avec `EntropyHub.SampEn` pour l'entropie Sample et avec `EntropyHub.FuzzEn` pour l'entropie Fuzzy. Nous fixons la dimension d'intégration à $m = 4$ et le seuil à $r = 0.2$. Les vecteurs de caractéristiques ainsi obtenus sont de dimensions 11×4 correspondant aux 11 électrodes et aux 4 bandes de fréquence.

Entropie croisée dynamique

Nous utilisons ces caractéristiques entropiques pour extraire l'entropie croisée dynamique DCE des électrodes frontales. La DCE est définie comme suit [4] :

$$DCE^{(f_1, f_2)}(y_1, \dots, y_c) = \frac{1}{\sum_{i=1}^c y_i^{(f_1, f_2)}} \quad (4.8)$$

Ici les $y_i^{(f_1, f_2)}$ sont les signaux filtrés dans la bande de fréquence f_1, f_2 de nos 11 électrodes frontales (donc avec $c = 11$).

Nous obtenons donc une valeur de DCE par bande de fréquences.

4.4.2 Architectures MLP basées sur l'entropie

Afin de déterminer l'importance de l'ajout de cette caractéristique d'entropie croisée dynamique, nous proposons et comparons trois architectures de perceptrons multicouches MLP.

Le modèle **MLP_Baseline** (Tableau 4.5) utilise uniquement les caractéristiques entropiques brutes, le modèle **MLP_DCE** (Tableau 4.6) uniquement les caractéristiques de DCE et le modèle hybride **MLP_Baseline+DCE** (Tableau 4.7) concatène les caractéristiques de la DCE à la représentation issue des données brutes avant la dernière couche dense.

TABLEAU 4.5 Architecture du modèle **MLP_Baseline** avec nombre de paramètres

Type de couche	Taille de sortie	Nb paramètres
Entrée ($x \in \mathbb{R}^{4 \times 11}$)	x	-
Flatten	44	-
Dense_1 (44→60)	60	2 700
BatchNorm1	60	120
ReLU	60	-
Dense_2 (60→10)	10	610
BatchNorm2	10	20
ReLU	10	-
Dropout ($p = 0,3$)	10	-
Dense_3 (10→1)	1	11
Sigmoïde	1	-
Total	—	3 461

TABLEAU 4.6 Architecture du modèle **MLP_DCE** avec nombre de paramètres

Type de couche	Taille de sortie	Nb paramètres
Entrée ($x \in \mathbb{R}^4$)	4	-
Dense_1 (4 → 15)	15	75
BatchNorm1	15	30
ReLU	15	-
Dense_2 (15 → 10)	10	160
BatchNorm2	10	20
ReLU	10	-
Dropout ($p = 0,3$)	10	-
Dense_3 (10 → 1)	1	11
Sigmoïde	1	-
Total	—	296

Nous utilisons ces trois architectures avec les caractéristiques entropiques Fuzzy et Sample (caractérisées par les préfixes **Sample_** et **Fuzzy_**) ainsi que pour les deux découpages de bandes de fréquences (caractérisés par les suffixes $_{\alpha\beta}$ et $_{\delta\theta\alpha\beta}$).

TABLEAU 4.7 Architecture du modèle **MLP_Baseline+DCE** avec nombre de paramètres

Type de couche	Taille de sortie	Nb paramètres
Entrée ($x \in \mathbb{R}^{12 \times 4}$)	$x + \text{DCE}$	-
Remove DCE ($x \in \mathbb{R}^{11 \times 4}$)	x	-
Flatten	44	-
Dense_1 (44 → 60)	60	2 700
BatchNorm1	60	120
ReLU	60	-
Dense_2 (60 → 4)	4	244
BatchNorm2	4	8
ReLU	4	-
Concaténation avec DCE	$4 + 4 = 8$	-
Dropout ($p = 0,3$)	8	-
Dense_3 (8 → 1)	1	9
Sigmoid	1	-
Total	—	3 081

4.5 Protocole expérimental

4.5.1 Séparation des données temporellement ou par participant

Afin de tester l'efficacité de tous ces modèles, nous allons effectuer une séparation des données par participant pour écarter des participants tests. Des 28 participants initiaux, 9 sont sélectionnés aléatoirement pour être des participants tests. Ils serviront à évaluer la capacité de généralisation de nos modèles.

L'hypothèse de généralisation à des participants inconnus est forte et risque de ne pas être suffisamment déterminante pour le choix de nos modèles. C'est pour cela que nous souhaitons avoir un objectif plus réalisable, la prédiction de données inconnues pour un participant dont nous extrayons des données de calibrage pour raffiner le modèle. Cette approche implique une forme de "patient leak".

Nous avons beaucoup de recouvrement (80%) entre deux données consécutives temporellement, effectuer une sélection aléatoire de données de test ne serait donc pas représentatif de la performance de nos modèles et ne permettrait pas de juger d'un potentiel surapprentissage. Pour cela nous allons séparer les données temporellement.

Pour rappel, nous avons, pour l'entraînement de nos modèles, pour chaque participant, deux enregistrements. Un neutre **VidNeutre** et un présentant des stimuli à caractère sexuel **VidSex** qui est supposé engendrer des impulsions sexuelles chez les participants. Nos fenêtres de données sont de taille $w = 6s$: chaque donnée, repérée par la signature temporelle T , comprend

l'enregistrement EEG entre $T - w$ et T . Il y a un pas $\sigma = 1s$ entre chacune des données.

Pour un participant i , qui a été gardé pour l'entraînement des modèles $i \notin \text{Participants tests}$, nous considérons l'ensemble des données de chacun des enregistrements $\mathcal{D}^{neutre}(i)$ et $\mathcal{D}^{sex}(i)$ comme un vecteur temporel où $\mathcal{D}^{enregistrement}(i)[t]$ correspond à la donnée de signature temporelle t .

Chaque enregistrement est un intervalle continu de données, notons $t_0^{neutre}(i), t_1^{neutre}(i)$ les signatures temporelles de début et de fin de l'enregistrement $\mathcal{D}^{neutre}(i)$. Dans le cas des enregistrements pour les scénarios **VidSex**, $t_0^{sex}(i)$ et $t_1^{sex}(i)$ correspondent aux bornes de l'intervalle sélectionné comme représentant un état excité.

Nous définissons

$$t_{train}^{neutre}(i) = t_0^{neutre}(i) + 0.6 \left(t_1^{neutre}(i) - t_0^{neutre}(i) \right)$$

$$t_{val}^{neutre}(i) = t_{train}^{neutre}(i) + 0.2 \left(t_1^{neutre}(i) - t_{train}^{neutre}(i) \right)$$

Dans le but de séparer temporellement les données de chaque scénario avec 60% pour l'entraînement, 20% pour la validation et 20% pour le test. Pour éviter tout chevauchement entre des données, nous définissons les ensembles de données d'entraînement, validation et test $\mathcal{D}_{train}^{neutre}(i)$, $\mathcal{D}_{val}^{neutre}(i)$ et $\mathcal{D}_{test}^{neutre}(i)$ de la façon suivante :

$$\mathcal{D}_{train}^{neutre}(i) = \left\{ \mathcal{D}^{neutre}(i)[t], t \in \left[t_0^{neutre}(i), t_{train}^{neutre}(i) - \left\lceil \frac{w}{2} \right\rceil \right] \right\}$$

$$\mathcal{D}_{val}^{neutre}(i) = \left\{ \mathcal{D}^{neutre}(i)[t], t \in \left[t_{train}^{neutre}(i) + \left\lceil \frac{w}{2} \right\rceil, t_{val}^{neutre}(i) - \left\lceil \frac{w}{2} \right\rceil \right] \right\}$$

$$\mathcal{D}_{test}^{neutre}(i) = \left\{ \mathcal{D}^{neutre}(i)[t], t \in \left[t_{val}^{neutre}(i) + \left\lceil \frac{w}{2} \right\rceil, t_1^{neutre}(i) \right] \right\}$$

Nous définissons de façon similaire $\mathcal{D}_{train}^{sex}(i)$, $\mathcal{D}_{val}^{sex}(i)$ et $\mathcal{D}_{test}^{sex}(i)$.

Nous obtenons donc pour tous les participants non écartés, les bases de données suivantes pour l'entraînement de nos modèles :

$$\mathcal{D}_{train} = \left\{ \bigcup_i \mathcal{D}_{train}^{sex}(i) \cup \mathcal{D}_{train}^{neutre}(i), i \notin \text{Participants Tests} \right\}$$

$$\mathcal{D}_{val} = \left\{ \bigcup_i \mathcal{D}_{val}^{sex}(i) \cup \mathcal{D}_{val}^{neutre}(i), i \notin \text{Participants Tests} \right\}$$

$$\mathcal{D}_{test} = \left\{ \bigcup_i \mathcal{D}_{test}^{sex}(i) \cup \mathcal{D}_{test}^{neutre}(i), i \notin \text{Participants Tests} \right\}$$

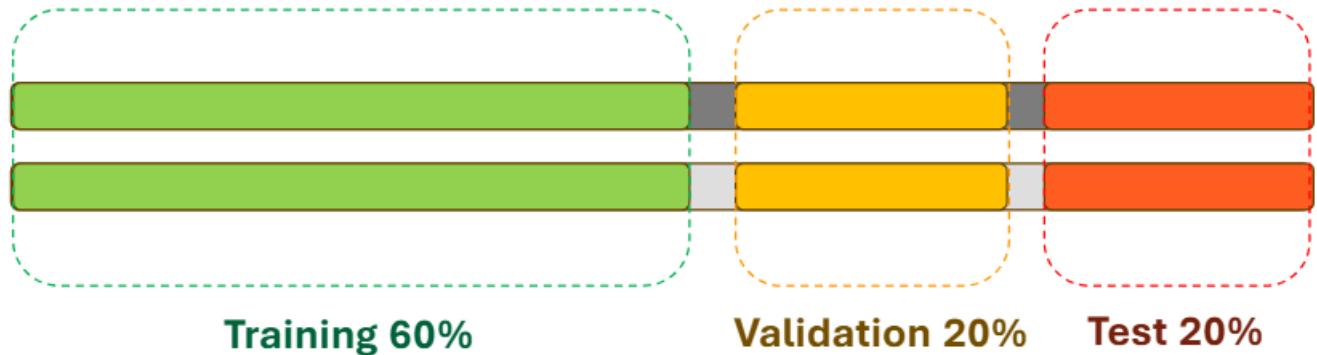


FIGURE 4.7 Illustration de la séparation temporelle des deux enregistrements d'un patient en données d'entraînement, de validation et de test .

4.5.2 Ajout ou non d'un prétraitement par ICA

Si aucune architecture ne de de résultats satisfaisants sur les données brutes, nous répétons le même protocole sur les données qui ont subi un prétraitement par ICA.

4.5.3 Généralisation à des patients inconnus et raffinage

Les modèles qui performent bien sur la base de données des participants retenus pour l'entraînement vont ensuite être testés sur les données des participants tests que nous avons écartés préalablement.

Pour vérifier si un raffinage des modèles est nécessaire nous effectuons sur chacun des enregistrements des patients test un découpage temporel. Ce découpage est similaire à celui des patients généraux car il isole les derniers 20% de chaque enregistrement comme données test et garde les premiers $x\%$ comme données de raffinage.

Le but de ces découpages est de mesurer la quantité de données de raffinage nécessaire à l'obtention d'une prédiction satisfaisante sur les données d'un patient.

Nous effectuons des raffinages en utilisant $x \in \{10\%, 20\%, 30\%, 40\%, 50\%, 60\%, 70\%\}$, nous obtenons ainsi pour chacune des architectures choisies, 7 modèles raffinés pour chaque patient.

En plus des modèles entraînés sur une base de patients généraux puis raffinés, nous entraînons également des modèles personnels seulement sur les données d'entraînement du patient ce qui amène le nombre total de modèles à 14 par architecture et par patient.

Ces modèles personnels et raffinés sont entraînés avec les mêmes hyperparamètres que les modèles originaux mais en divisant le nombre d'epochs par 10.

4.5.4 Visualisation de l'inférence des modèles

La dernière vérification de nos modèles se fait de manière qualitative en visualisant l'inférence de nos modèles temporellement superposés à la courbe de PPG de chaque enregistrement.

De cette manière nous pouvons visualiser le fonctionnement des modèles sur les données Vidéos qui comprennent les données de test et d'entraînement mais aussi, pour les scénarios **VidSex**, des données non étiquetées.

Nous observons également la capacité de généralisation des modèles aux scénarios générés en 3D où nous nous attendons à obtenir des prédictions positives sur les pics de PPG pour les scénarios **PVP_EVI** (scénarios 3D présentant une interaction érotique avec un avatar 3D donc des stimuli sexuels) et des prédictions neutres pour les scénarios **Androïde** qui ne présentent pas d'interaction érotique avec le personnage 3D.

CHAPITRE 5 RÉSULTATS

5.1 Comparaison des modèles sur des patients connus

Pour évaluer la capacité de nos modèles à prédire l'impulsion sexuelle et sélectionner les architectures les plus efficaces, nous regardons les résultats de nos modèles sur le jeu de données des participants d'entraînement avec la séparation temporelle comme décrit dans la section 4.5.1.

5.1.1 Résultats sur les données brutes

Modèle	Test Loss	Accuracy	Recall	Precision	F1 Score
SpectroCNN_res	28.185	0.674	0.968	0.675	0.796
SpectroCNN_3	31.415	0.661	0.991	0.661	0.793
SpectroCNN_5	30.010	0.659	0.983	0.661	0.791
RA-CNN	10.012	0.585	0.715	0.672	0.693
R-CNN	4.469	0.512	0.570	0.645	0.605
A-CNN	2.924	0.575	0.669	0.678	0.673
Fuzzy_MLP_Baseline_δθαβ	0.680	0.659	0.759	0.731	0.745
Fuzzy_MLP_DCE_δθαβ	0.631	0.650	0.965	0.659	0.783
Fuzzy_MLP_Baseline+DCE_δθαβ	0.700	0.621	0.663	0.733	0.696
Sample_MLP_Baseline_δθαβ	0.746	0.558	0.718	0.647	0.680
Sample_MLP_DCE_δθαβ	0.686	0.608	0.924	0.639	0.755
Sample_MLP_Baseline+DCE_δθαβ	0.669	0.600	0.817	0.657	0.728
Fuzzy_MLP_Baseline_αβ	0.724	0.600	0.640	0.719	0.677
Fuzzy_MLP_DCE_αβ	0.639	0.640	0.962	0.653	0.778
Fuzzy_MLP_Baseline+DCE_αβ	0.656	0.651	0.773	0.717	0.744
Sample_MLP_Baseline_αβ	0.719	0.598	0.785	0.663	0.719
Sample_MLP_DCE_αβ	0.680	0.619	0.945	0.642	0.765
Sample_MLP_Baseline+DCE_αβ	0.726	0.587	0.791	0.652	0.715

TABLEAU 5.1 Performance des modèles sur les données brutes des patients connus.

En premier lieu, nous nous intéressons aux résultats sur les données brutes, celles qui n'ont pas suivi le prétraitement par ICA décrit en 4.1.3.

La première observation que l'on peut tirer du tableau 5.1 est qu'aucune des architectures présentées n'atteint une exactitude (**Accuracy**) suffisamment satisfaisante pour pouvoir continuer à être utilisée sans améliorations.

Parmi tous les modèles, les réseaux convolutionnels basés sur des spectrogrammes **SpectroCNN_res**,

`SpectroCNN_3` et `SpectroCNN_5` obtiennent la meilleure exactitude et des scores de rappel élevés supérieures à 0.9. Cependant la précision reste relativement faible et la perte (**Loss**) est très élevée, ce qui indique une tendance à prédire excessivement des cas positifs au détriment de la fiabilité et que, lorsque les modèles se trompent, ils font des erreurs significatives. Les modèles basés sur les caractéristiques entropiques (avec ajout ou non de l'entropie croisée dynamique) présentent des métriques plus équilibrées.

Pour essayer de mieux comprendre les éventuelles causes du mauvais fonctionnement de nos modèles nous nous intéressons à l'exactitude obtenue sur les données de test, d'entraînement et de validation : \mathcal{D}_{test} , \mathcal{D}_{train} , \mathcal{D}_{val} définies en 4.5.1.

En regardant les résultats du Tableau 5.2, nous nous apercevons que les modèles basés sur l'extraction de caractéristiques temporelles profondes R_CNN, A_CNN et RA_CNN présentent un surapprentissage évident avec des exactitudes supérieures à 0.9 sur les données d'entraînement et inférieures à 0.6 sur les données de test. Cela est très probablement lié à la taille de ces modèles qui sont trop lourds et trop complexes pour le petit jeu de données dont nous disposons.

De même, nous pourrions nous attendre à observer du surapprentissage dans les réseaux convolutifs basés sur les spectrogrammes mais ce n'est pas le cas. Les couches de normalisation par lot (**BatchNorm**) et de désactivation aléatoire (**Dropout**) ont suffi à l'empêcher.

5.1.2 Résultats sur les données avec ICA

Au vu des faibles exactitudes obtenues sur les données brutes, nous nous intéressons aux données qui ont été préalablement soumises à un prétraitement ICA comme décrit en 4.1.3.

Nous observons dans le tableau 5.3 que les modèles basés sur l'analyse des caractéristiques entropiques sont plus performants que les approches par analyse de spectrogrammes ou extraction profonde de caractéristiques temporelles.

Nous remarquons que l'ajout de l'entropie croisée dynamique n'améliore pas significativement les performances du modèle et que les prédictions des architectures basées sur cette seule caractéristique ne sont pas fiables.

Les architectures basées sur les caractéristiques d'entropie de type "Fuzzy" sont plus performantes que celles basées sur l'entropie "Sample". En particulier, l'architecture `Fuzzy_MLP_Baseline` obtient une exactitude de **0.922** et domine largement toutes les autres.

La variante `Fuzzy_MLP_Baseline_δθαβ` dont le découpage en bandes de fréquences est élargi (voir 4.4.1) pour inclure les ondes δ et θ semble mieux performer que la variante `Fuzzy_MLP_Baseline_αβ` qui se base seulement sur les ondes α et β (voir 4.4.1).

Modèle	Test Accuracy	Train Accuracy	Val Accuracy
SpectroCNN_res	0.674	0.695	0.675
SpectroCNN_3	0.661	0.626	0.661
SpectroCNN_5	0.659	0.635	0.669
RA-CNN	0.585	0.982	0.618
R-CNN	0.512	0.972	0.654
A-CNN	0.575	0.963	0.642
Fuzzy_MLP_Baseline_δθαβ	0.659	0.844	0.600
Fuzzy_MLP_DCE_δθαβ	0.650	0.620	0.663
Fuzzy_MLP_Baseline+DCE_δθαβ	0.621	0.818	0.624
Sample_MLP_Baseline_δθαβ	0.558	0.786	0.646
Sample_MLP_DCE_δθαβ	0.608	0.619	0.659
Sample_MLP_Baseline+DCE_δθαβ	0.600	0.760	0.656
Fuzzy_MLP_Baseline_αβ	0.600	0.847	0.638
Fuzzy_MLP_DCE_αβ	0.640	0.622	0.663
Fuzzy_MLP_Baseline+DCE_αβ	0.651	0.808	0.650
Sample_MLP_Baseline_αβ	0.598	0.755	0.644
Sample_MLP_DCE_αβ	0.619	0.622	0.654
Sample_MLP_Baseline+DCE_αβ	0.587	0.735	0.663

TABLEAU 5.2 Performance des modèles sur les ensembles de test, entraînement et validation des données brutes.

5.2 Généralisation aux patients inconnus

5.2.1 Résultats sans fine-tuning

Nous pouvons observer dans le tableau 5.4 les exactitudes obtenues par les trois architectures les plus performantes vues en 5.3 lorsqu'elles sont évaluées sur les données de participants inconnus (les `Participants tests` vus en 4.5.1).

Les architectures évaluées sont celles des modèles `Fuzzy_MLP`, notamment les variantes `Baseline_δθαβ`, `Baseline_αβ` et `Baseline+DCE_αβ`.

Les résultats montrent que les performances restent globalement faibles, avec des moyennes allant d'une exactitude de **0.400** pour `Baseline_δθαβ` à **0.494** pour `Baseline+DCE_αβ`.

Ces résultats indiquent que les modèles se généralisent mal à des participants inconnus, ce qui met en évidence une limite importante dans leur capacité à capturer des représentations transférables entre individus.

Bien que les variantes `_αβ` semblent légèrement plus performantes et pourraient favoriser une meilleure robustesse face à des données hors distribution, les performances de ces modèles suggèrent qu'un raffinage par patient est nécessaire.

Modèle	Test Loss	Accuracy	Recall	Precision	F1 Score
SpectroCNN_res	5.59	0.586	0.475	0.816	0.601
SpectroCNN_3	21.9	0.373	0.0609	0.778	0.113
SpectroCNN_5	13.8	0.456	0.209	0.847	0.335
A-CNN	2.59	0.606	0.678	0.709	0.693
R-CNN	3.27	0.692	0.843	0.729	0.782
RA-CNN	18.2	0.568	0.667	0.673	0.670
Fuzzy_MLP_Baseline_ $\delta\theta\alpha\beta$	0.273	0.922	0.907	0.972	0.939
Fuzzy_MLP_DCE_ $\delta\theta\alpha\beta$	0.606	0.635	0.849	0.677	0.753
Fuzzy_MLP_Baseline+DCE_ $\delta\theta\alpha\beta$	0.469	0.871	0.843	0.954	0.895
Sample_MLP_Baseline_ $\delta\theta\alpha\beta$	0.884	0.551	0.658	0.658	0.658
Sample_MLP_DCE_ $\delta\theta\alpha\beta$	0.650	0.650	0.986	0.655	0.787
Sample_MLP_Baseline+DCE_ $\delta\theta\alpha\beta$	0.727	0.549	0.739	0.634	0.683
Fuzzy_MLP_Baseline_ $\alpha\beta$	0.363	0.905	0.887	0.965	0.924
Fuzzy_MLP_DCE_ $\alpha\beta$	0.614	0.624	0.797	0.682	0.735
Fuzzy_MLP_Baseline+DCE_ $\alpha\beta$	0.353	0.903	0.878	0.971	0.922
Sample_MLP_Baseline_ $\alpha\beta$	0.939	0.536	0.675	0.638	0.656
Sample_MLP_DCE_ $\alpha\beta$	0.650	0.654	0.994	0.656	0.790
Sample_MLP_Baseline+DCE_ $\alpha\beta$	0.651	0.616	0.852	0.660	0.744

TABLEAU 5.3 Performance des modèles sur les données avec prétraitement ICA

Participant	Baseline_ $\delta\theta\alpha\beta$	Baseline_ $\alpha\beta$	Baseline+DCE_ $\alpha\beta$
Participant test ₁	0.220	0.400	0.600
Participant test ₂	0.645	0.364	0.576
Participant test ₃	0.350	0.833	0.167
Participant test ₄	0.652	0.345	0.655
Participant test ₅	0.174	0.370	0.222
Participant test ₆	0.600	0.500	0.500
Participant test ₇	0.171	0.357	0.357
Participant test ₈	0.203	0.310	0.690
Participant test ₉	0.584	0.516	0.677
Moyenne	0.400	0.444	0.494

TABLEAU 5.4 Exactitudes des modèles les plus performants sur les données test des participants inconnus

5.2.2 Résultats avec raffinage du modèle général

Les tableaux 5.5, 5.6 et 5.7 présentent les exactitudes obtenues par nos modèles en fonction de la proportion de données utilisées pour le raffinage (proportion x comme vu en 4.5.3).

On observe en 5.5 que le modèle Baseline_ $\delta\theta\alpha\beta$ est celui qui nécessite le moins de raffinage, avec une exactitude de **0.783** pour seulement 30% des données utilisées pour le raffinage et

Proportion entraînement	Aucune	0.1	0.2	0.3	0.4	0.5	0.6	0.7
Participant test ₁	0.220	0.940	0.820	0.980	0.920	0.920	0.920	0.920
Participant test ₂	0.645	0.615	0.676	0.676	0.645	0.676	0.676	0.706
Participant test ₃	0.350	0.767	0.850	0.850	0.933	0.850	0.850	0.850
Participant test ₄	0.652	0.686	0.790	0.824	0.790	0.652	0.617	0.755
Participant test ₅	0.174	0.470	0.507	0.656	0.730	0.841	0.989	0.989
Participant test ₆	0.600	0.767	0.767	0.711	0.711	0.767	0.767	0.767
Participant test ₇	0.171	0.636	0.671	0.743	0.957	0.921	0.993	0.929
Participant test ₈	0.203	0.721	0.755	0.859	0.931	0.900	0.900	0.966
Participant test ₉	0.584	0.648	0.810	0.745	0.745	0.713	0.681	0.648
Moyenne	0.400	0.694	0.738	0.783	0.840	0.838	0.855	0.870

TABLEAU 5.5 Exactitudes en fonction du pourcentage de données utilisées pour le raffinement des modèles Fuzzy_MLP_Baseline_δθαβ

Proportion entraînement	Aucune	0.1	0.2	0.3	0.4	0.5	0.6	0.7
Participant test ₁	0.400	0.240	0.480	0.560	0.560	0.520	0.600	0.560
Participant test ₂	0.364	0.818	0.848	0.788	0.818	0.788	0.758	0.758
Participant test ₃	0.833	0.333	0.167	0.083	0.250	0.250	0.333	0.417
Participant test ₄	0.345	0.759	0.724	0.759	0.862	0.897	0.966	0.966
Participant test ₅	0.370	0.704	0.963	0.926	1.000	0.963	0.963	0.963
Participant test ₆	0.500	0.444	0.444	0.556	0.611	0.778	0.833	0.778
Participant test ₇	0.357	0.536	0.643	0.893	0.929	0.929	1.000	1.000
Participant test ₈	0.310	0.828	0.828	0.897	0.931	0.897	0.897	0.931
Participant test ₉	0.516	0.258	0.258	0.258	0.419	0.419	0.419	0.484
Moyenne	0.444	0.547	0.595	0.635	0.709	0.716	0.752	0.762

TABLEAU 5.6 Exactitudes en fonction du pourcentage de données utilisées pour le raffinement des modèles d'architecture Fuzzy_MLP_Baseline_αβ

0.840 quand lorsque la proportion atteint 40%.

Les modèles Baseline_αβ et Baseline+DCE_αβ n'affichent pas de progrès aussi satisfaisants et les résultats deviennent acceptables (≥ 0.7) seulement quand la proportion de données est plus importante et atteignent des exactitudes maximales à **0.762** et **0.736**.

Ainsi, c'est bien le modèle textttBaseline_δθαβ qui, malgré une mauvaise généralisation aux participants inconnus, se raffine le plus efficacement avec un moindre ajout de données.

5.2.3 Résultats avec modèles personnalisés

Comme annoncé en 4.5.3, en plus des modèles généraux raffinés, nous entraînons également, pour ces trois architectures choisies, des modèles personnalisés entraînés uniquement sur les

Proportion entraînement	Aucune	0.1	0.2	0.3	0.4	0.5	0.6	0.7
Participant test ₁	0.600	0.320	0.480	0.520	0.520	0.600	0.720	0.720
Participant test ₂	0.576	0.667	0.545	0.606	0.545	0.455	0.485	0.485
Participant test ₃	0.167	0.333	0.250	0.167	0.417	0.500	0.583	0.583
Participant test ₄	0.655	0.759	0.931	0.931	0.931	0.931	0.966	1.000
Participant test ₅	0.222	0.481	0.630	0.741	0.889	0.926	0.926	0.963
Participant test ₆	0.500	0.278	0.611	0.444	0.333	0.278	0.444	0.389
Participant test ₇	0.357	0.679	0.643	0.786	0.857	1.000	1.000	1.000
Participant test ₈	0.690	0.759	0.828	0.897	0.966	1.000	1.000	1.000
Participant test ₉	0.677	0.161	0.194	0.226	0.355	0.484	0.484	0.484
Moyenne	0.494	0.493	0.568	0.591	0.646	0.686	0.734	0.736

TABLEAU 5.7 Exactitudes en fonction du pourcentage de données utilisées pour le raffinement des modèles d'architecture Fuzzy_MLP_Baseline+DCE_αβ

données du participant sélectionné.

Proportion entraînement	0.1	0.2	0.3	0.4	0.5	0.6	0.7
Participant_test ₁	0.600	0.600	0.440	0.800	0.840	0.840	0.960
Participant_test ₂	0.364	0.515	0.636	0.636	0.636	0.727	0.758
Participant_test ₃	0.833	0.167	0.667	0.167	0.917	0.833	0.750
Participant_test ₄	0.345	0.448	0.828	1.000	0.655	0.552	0.724
Participant_test ₅	0.370	0.741	0.370	0.926	0.481	0.778	0.778
Participant_test ₆	0.611	0.500	0.333	0.500	0.500	0.500	0.444
Participant_test ₇	0.357	0.643	0.357	0.714	0.964	0.357	1.000
Participant_test ₈	0.793	0.690	0.931	0.724	0.862	0.828	1.000
Participant_test ₉	0.323	0.323	0.452	0.387	0.323	0.323	0.548
Moyenne	0.511	0.514	0.557	0.650	0.687	0.637	0.774

TABLEAU 5.8 Exactitudes en fonction du pourcentage de données utilisées pour l'entraînement d'un modèle Fuzzy_MLP_Baseline_δθαβ

Les tableaux 5.8, 5.9 et 5.10 présentent les exactitudes obtenues par les modèles Baseline_δθαβ, Baseline_αβ et Baseline+DCE_αβ lorsqu'ils sont raffinés uniquement sur les données du participant évalué.

Il apparaît clairement que les modèles Baseline_δθαβ et Baseline_αβ sont bien plus performants et atteignent des exactitudes élevées (respectivement **0.774** et **0.720** avec 70% des données) là où le modèle Baseline+DCE_αβ ne présente pas de métrique satisfaisante quelle que soit la proportion de données d'entraînement.

On remarque cependant que même si les performances peuvent être jugées satisfaisantes, elles nécessitent une plus grande portion de données du participant pour l'entraînement. Le

Proportion entraînement	0.1	0.2	0.3	0.4	0.5	0.6	0.7
Participant_test ₁	0.560	0.440	0.440	0.680	0.560	0.520	0.480
Participant_test ₂	0.545	0.333	0.667	0.606	0.455	0.606	0.545
Participant_test ₃	0.167	0.833	0.833	0.167	0.500	0.833	0.417
Participant_test ₄	0.655	0.655	0.655	0.724	0.966	0.966	0.966
Participant_test ₅	0.481	0.704	0.926	0.444	1.000	0.667	1.000
Participant_test ₆	0.500	0.500	0.611	0.500	0.722	0.611	0.667
Participant_test ₇	0.429	0.857	0.393	0.464	0.464	0.393	0.821
Participant_test ₈	0.310	0.379	0.379	1.000	0.931	0.897	1.000
Participant_test ₉	0.677	0.645	0.355	0.323	0.387	0.355	0.581
Moyenne	0.481	0.594	0.584	0.545	0.665	0.650	0.720

TABLEAU 5.9 Exactitudes en fonction du pourcentage de données utilisées pour l'entraînement d'un modèle *Fuzzy_MLP_Baseline_* $\alpha\beta$

Proportion entraînement	0.1	0.2	0.3	0.4	0.5	0.6	0.7
Participant_test ₁	0.600	0.400	0.400	0.960	0.520	0.560	0.400
Participant_test ₂	0.636	0.364	0.636	0.394	0.364	0.636	0.697
Participant_test ₃	0.833	0.833	0.250	0.833	0.167	0.167	0.167
Participant_test ₄	0.655	0.345	0.828	0.690	0.448	0.793	0.966
Participant_test ₅	0.037	0.630	0.630	0.370	0.370	1.000	0.407
Participant_test ₆	0.500	0.500	0.500	0.500	0.722	0.500	0.500
Participant_test ₇	0.643	0.357	0.571	0.857	0.536	0.571	0.357
Participant_test ₈	0.690	0.690	0.828	0.310	0.379	0.724	0.310
Participant_test ₉	0.355	0.677	0.677	0.323	0.323	0.323	0.419
Moyenne	0.550	0.533	0.591	0.582	0.425	0.586	0.469

TABLEAU 5.10 Exactitudes moyennes selon la proportion de données d'entraînement d'un modèle *Fuzzy_MLP_Baseline+DCE_* $\alpha\beta$

modèle *Baseline_* $\delta\theta\alpha\beta$ atteint une exactitude moyenne de **0.840** pour seulement 40% de données de raffinement contre seulement **0.650** lorsqu'il est entraîné uniquement sur les données du participant.

Ces résultats montrent qu'utiliser un modèle de base pré-entraîné puis raffiné par rapport à un modèle basé uniquement sur les données du participant à analyser permet d'atteindre une meilleure exactitude, plus rapidement et avec un moindre coût en ressources.

5.3 Analyse qualitative des modèles par visualisation de l'inférence

Nous avons vu que sur les données avec un prétraitement par ICA, avec une architecture *Fuzzy_MLP_Baseline_* $\delta\theta\alpha\beta$ nous atteignons une exactitude de **0.922** sur des patients connus

et de **0.840** en raffinant le modèle sur 40% des données d'un participant inconnu.

Pour voir si nos modèles se généralisent en dehors des données étiquetées, nous cherchons à visualiser si l'inférence d'une impulsion sexuelle par notre modèle correspond au scénario dans lequel le patient est immergé et avec la courbe PPG.

La courbe de pléthysmographie pénienne PPG mesure l'engorgement de l'appareil génital et reflète généralement, chez nos participants mâles cisgenres, une réponse physiologique à un stimulus sexuel, une impulsion sexuelle.

Les graphiques des figures 5.1 et 5.2 présentent cette courbe de PPG en bleu et surligne en gris les instants t (voir 4.1.2) où le modèle infère une impulsion sexuelle.

Les données ayant servi à l'entraînement du modèle sont surlignées en vert et celles sur lesquelles les métriques de test ont été calculées en rouge (voir 4.5.1 et 4.5.3)

Malheureusement, nous ne possédons pas les données du `Participant_test9` dans les scénarios générés en 3D donc l'inférence sera réalisée uniquement sur les 8 premiers `Participant_tests`.

Les figures de résultats similaires obtenus sur tous ces participants sont placées à l'annexe A (A.1, A.2, A.3, A.4, A.5, A.6, A.7 et A.8). Nous observons sur toutes ces figures d'inférence les mêmes phénomènes.

Comme indiqué par les métriques utilisées pour les données étiquetées, la prédiction dans le cadre des scénarios vidéo : `VidNeutre` et `VidSex` est médiocre pour le modèle général mais nettement améliorée dans le cadre de l'utilisation des modèles raffinés.

Cependant, la généralisation de nos modèles généraux ou raffinés aux scénarios immersifs générés en 3D, tels que `Androide` et `PVP-EVI`, ne semble pas satisfaisante. Nous pourrions nous attendre à observer davantage d'inférences d'impulsions sexuelles dans les immersions `PVP-EVI` par rapport à `Androide`, en raison de leur contenu scénaristique, mais cela n'est pas confirmé par les résultats obtenus.

En particulier, la courbe de PPG des `Participants_tests` 3, 7 et 8 présente un pic d'excitation physiologique notable lors de l'exposition au scénario `PVP-EVI`, qui reste largement ignoré ou mal interprété par les modèles.

Ce constat souligne les limites actuelles de notre système qui peine à ce généraliser aux scénarios d'immersion en environnements 3D.

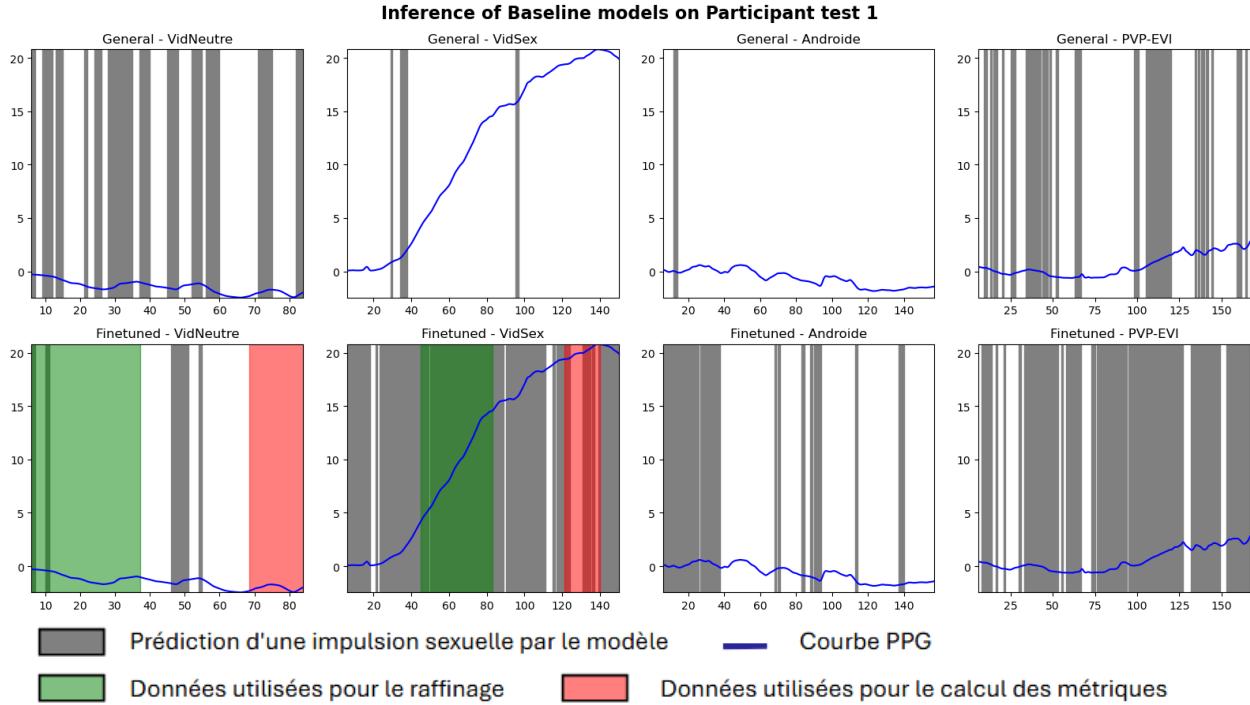


FIGURE 5.1 Inférence du modèle général et raffiné sur le Participant Test 1

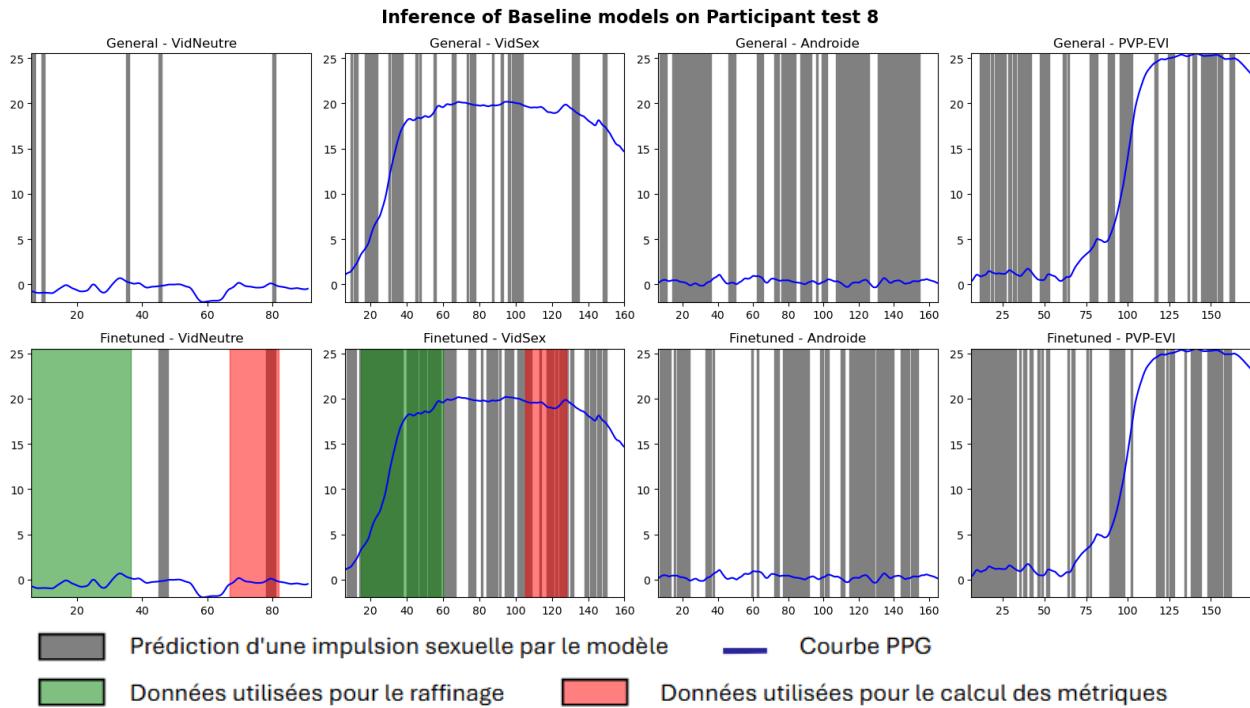


FIGURE 5.2 Inférence du modèle général et raffiné sur le Participant Test 8

CHAPITRE 6 DISCUSSION

6.1 Rappel des contraintes souhaitées pour des futures utilisations des modèles

6.1.1 Utilisation en temps réel

L'un des objectifs principaux de nos travaux est de mettre en place un outil de prédiction en temps réel qui est adapté à un traitement des données en flux.

Pour une application en temps réel, la prédiction doit être effectuée à chaque seconde (voir 4.1.2). À l'instant t la chaîne de traitement doit, en moins d'une seconde, pouvoir effectuer le prétraitement des données, d'extraire les caractéristiques et d'effectuer une prédiction via le modèle choisi.

Le prétraitement doit donc être rapide et causal, idéalement applicable avec la seule connaissance des données du segment en cours de traitement. Le but de notre outil est d'effectuer une prédiction chaque seconde pour simuler une prédiction temps réel, par conséquent, le temps nécessaire à l'extraction des caractéristiques et l'inférence ne doit pas dépasser 1 seconde.

6.1.2 Généralisation facile à des patients inconnus

L'un des enjeux majeurs pour une utilisation en conditions réelles est la capacité du modèle à généraliser à de nouveaux participants facilement.

Les résultats obtenus en validation inter-patient ont mis en évidence une baisse significative des performances de généralisation pour tous nos modèles, et ont mis en avant la nécessité d'utiliser, pour chaque nouveau participant, une étape de raffinement du modèle pour restaurer un niveau de performance acceptable. Ce raffinement peut être assimilé à une calibration de l'outil au participant.

Toutefois, ce raffinement doit respecter plusieurs contraintes :

- Le modèle doit pouvoir être adapté rapidement, idéalement en quelques secondes, pour une intégration fluide dans un futur protocole clinique.
- Le raffinement doit être possible avec un nombre limité de données, sans nécessiter une nouvelle phase d'apprentissage complète.

L'architecture la plus performante est `Fuzzy_MLP_Baseline_δθαβ`. Même si elle ne se généralise que très mal à des patients inconnus, une faible quantité de données (40 % ce qui correspond à environ 30 secondes de données neutres et 30 secondes de données stimulantes) permet d'obtenir des résultats satisfaisants.

De plus cette architecture est simple 4.5 et le temps nécessaire au raffinage (moins de 15 secondes sur un CPU) est suffisamment faible pour ne pas causer de délais trop contraignant pour un futur protocole clinique.

6.2 Nécessité du prétraitement par ICA

Comme vu précédemment dans les tableaux 5.1.1 et 5.1.2 seules les données ayant subi un prétraitement ICA permettent l'obtention de performances utilisables.

6.2.1 Incompatibilité du prétraitement original avec une utilisation en temps réel

Le prétraitement décrit en 4.1.3 utilisé par [4] repose sur de longues fenêtres temporelles et une connaissance globale du signal EEG, ce qui le rend incompatible avec une application en temps réel sur des fenêtres courtes.

L'inspection visuelle des canaux bruités nécessite une intervention humaine et un accès à l'ensemble des données, ce qui rend son utilisation incompatible avec un traitement des données en temps réel.

De plus, l'analyse en composantes indépendantes (ICA), notamment avec l'algorithme Info-max, requiert une quantité substantielle de données pour estimer les matrices de séparation, ce qui la rend non causale et donc inadaptée à une utilisation sur des segments courts sans accès aux données futures.

Enfin, la sélection de segments exempts d'artefacts repose sur une analyse a posteriori, incompatible avec le traitement en continu souhaité pour une future utilisation en temps réel.

6.2.2 Prétraitement alternatif compatible avec des fenêtres courtes

Pour permettre un futur traitement en temps réel sur des fenêtres courtes, il serait nécessaire d'adopter une approche causale et légère.

La détection des canaux bruités peut être approchée automatiquement via des métriques en ligne telles que la variance, les lignes plates ou le bruit haute fréquence.

Le retrait des artefacts oculaires peut être réalisé en combinant des données oculométriques aux signaux EEG, les données de mouvement oculaire sont récoltées dans les travaux de Brideau-Duquette [4] et pourraient éventuellement être utilisées pour détecter et corriger automatiquement ces artefacts ou ignorer les segments de données les contenant.

La nécessité d'utiliser des données de calibration permettra de calculer les mastoides et la moyenne commune sur les données d'entraînement et d'utiliser ces derniers pour appliquer un traitement par ICA au reste du signal. Mais la validité et la faisabilité de cette méthode reste à prouver.

6.3 Utilisation de modèles basés sur l'entropie

Même si l'utilisation de modèles légers basés sur les caractéristiques entropiques permet une inférence très rapide et un temps nécessaire au raffinage suffisamment court, la méthode utilisée dans nos travaux pour extraire ces caractéristiques est incompatible avec le temps réel.

6.3.1 Complexité et temps de calcul des caractéristiques entropiques

L'extraction des caractéristiques entropiques `Sample`, `Fuzzy`, repose sur des calculs de distances entre motifs temporels, des seuillages, et des opérations logarithmiques sur des vecteurs de grande taille. Ces opérations sont coûteuses en temps de calcul, surtout lorsqu'elles sont appliquées à chaque fenêtre glissante du signal EEG.

Notre implémentation du calcul de ces caractéristiques via `EntropyHub` est due à la facilité d'utilisation de cette librairie mais n'est pas optimisée.

Dans nos expérimentations, le temps nécessaire pour extraire les entropies sur une seule fenêtre de 6 secondes dépasse largement le temps disponible pour une prédiction en temps réel (1 seconde). Cela rend l'utilisation directe de ces méthodes impossible dans un pipeline de traitement continu sans optimisation.

6.3.2 Calcul parallélisable possible

L'implémentation actuelle via la bibliothèque `EntropyHub` en Python ne permet pas de parallélisation native. Les fonctions de calcul d'entropie sont exécutées de manière séquentielle, ce qui leur empêche d'exploiter pleinement les systèmes multicœurs ou GPU.

Cependant, les calculs de caractéristiques entropiques sont, par nature, hautement parallélisables. Une implémentation optimisée permettrait de les rendre compatibles avec les architectures GPU. Une telle optimisation permettrait de réduire drastiquement le temps de calcul et de rendre l'extraction entropique compatible avec une utilisation en temps réel.

CHAPITRE 7 CONCLUSION

7.1 Synthèse des travaux

7.1.1 Performance sur participants connus

Les modèles MLP basés sur l'entropie, notamment ceux utilisant l'entropie Fuzzy combinée à un prétraitement ICA, ont montré les meilleures performances pour la détection d'impulsions sexuelles sur des participants connus. Ces modèles surpassent les architectures CNN basées sur des représentations spectrographiques et régionales asymétriques. Bien que la petite taille du jeu de données favorise grandement les modèles simples avec un nombre de paramètres plus faible.

L'ajout de caractéristiques d'entropie croisée dynamique et la limitation des caractéristiques aux bandes de fréquences α et β ne semblent pas améliorer les performances.

7.1.2 Généralisation aux participants inconnus

Sans raffinage personnalisé, les modèles présentent une faible capacité de généralisation à des individus non vus pendant l'entraînement.

Toutefois, l'intégration d'un processus de raffinement, même avec une quantité limitée de données spécifiques au participant, permet une amélioration significative des performances. Les modèles raffinés atteignent une exactitude élevée plus rapidement que les modèles personnalisés entraînés uniquement sur les données du participant.

Analyse qualitative

L'analyse qualitative des inférences montre une bonne cohérence avec les réponses physiologiques mesurées, notamment dans les scénarios vidéo. Les modèles raffinés produisent des résultats plus fiables que les modèles généraux, confirmant l'intérêt d'une personnalisation légère pour améliorer la précision des prédictions.

Cependant, les modèles ne se généralisent que très mal pour l'immersion dans les scénarios générés en 3D ce qui pose problème pour de futures utilisations.

7.2 Limites de la solution proposée

Malgré les performances prometteuses obtenues sur les participants connus, plusieurs limitations freinent l'application directe des modèles proposés dans un contexte clinique en temps réel.

7.2.1 Mauvaise généralisation

Nécessité d'un raffinage

Même si le raffinage est rapide et ne nécessite que peu de données, il est nécessaire à l'obtention de bonnes performances et très contraignant pour la mise en place d'un protocole clinique qui impliquerait d'immerger chaque nouveau participant dans deux scénarios (un neutre et un avec stimuli érotiques) et de trouver un moyen non-intrusif d'étiqueter les données obtenues.

Mauvaise généralisation aux scénarios générés en 3D

Même avec l'utilisation de données de raffinage, la baisse de fiabilité lors de la généralisation à l'immersion dans des scénarios 3D est un frein à une future utilisation de cet outil dans un protocole clinique.

7.2.2 Incompatibilité avec le temps réel

Prétraitement non causal

Le prétraitement par ICA, indispensable pour obtenir des performances acceptables, repose sur une analyse globale du signal et une inspection manuelle, ce qui le rend incompatible avec une utilisation en temps réel.

Extraction de caractéristiques entropiques trop coûteuses

L'extraction des caractéristiques entropiques, bien qu'efficace pour la classification, est trop coûteuse en temps de calcul pour une application en flux continu. L'implémentation actuelle ne permet pas d'effectuer une prédiction chaque seconde comme requis.

7.3 Améliorations futures

Plusieurs pistes d'amélioration peuvent être envisagées pour surmonter les limitations identifiées et rendre les modèles plus adaptés à une utilisation clinique :

7.3.1 Optimisation du calcul entropique

Pour permettre un traitement en flux de données adapté à un protocole clinique en temps réel, une réimplémentation des mesures entropiques en environnement GPU est nécessaire. Cela permettrait de réduire drastiquement le temps de calcul et de rendre l'extraction compatible avec le temps réel.

7.3.2 Prétraitement causal et automatisé

Le remplacement du traitement par ICA par des méthodes légères et causales. On peut par exemple envisager des méthodes de détection automatique de canaux bruités. Pour le retrait des artefacts liées au mouvements des yeux, l'intégration des données oculométriques est une alternative prometteuse.

7.3.3 Améliorer la robustesse à de nouveaux environnements immersifs

La trop grande variabilité des signaux EEG limite la capacité de nos modèles à se généraliser. L'intégration d'autres données physiologiques notamment, oculométriques dans des chaînes de prédiction multimodales est une piste de recherche à explorer. Une attention particulière doit être portée à l'amélioration des performances dans les scénarios 3D.

7.3.4 Validation sur un plus grand échantillon

L'élargissement du jeu de données à plus de participants permettrait de mieux évaluer la robustesse des modèles, de pouvoir entraîner des architectures plus lourdes et plus complexes et de réduire le risque de sur-apprentissage sur des profils spécifiques.

Il est également pertinent d'augmenter le nombre de participants afin d'obtenir une population plus diversifiée tant en terme d'âge que de genre et d'orientation.

RÉFÉRENCES

- [1] P. Renaud *et al.*, “Using immersive virtual reality and ecological psychology to probe into child molesters’ phenomenology,” *Journal of Sexual Aggression*, vol. 19, p. 102–120, 2011. [En ligne]. Disponible : <https://doi.org/10.1080/13552600.2011.580575>
- [2] P. Fromberger *et al.*, “Virtual viewing time : the relationship between presence and sexual interest in androphilic and gynephilic men,” *PLOS ONE*, vol. 10, n°. 5, p. e0127156, 2015. [En ligne]. Disponible : <https://doi.org/10.1371/journal.pone.0127156>
- [3] P. Renaud *et al.*, “Sexual presence : A qeeg analysis of sexual arousal to synthetic pornography,” *International Journal of Telepresence*, vol. 1, p. 1–12, 2020. [En ligne]. Disponible : https://www.researchgate.net/publication/346554336_Sexual_Presence_A_qEEG_Analysis_of_Sexual_Arousal_to_Synthetic_Pornography
- [4] M. Brideau-Duquette *et al.*, “First probe into frontal eeg dynamic cross-entropy associated with virtual sexual content,” dans *Intelligent Human Systems Integration (IHSI 2024)*, vol. 119. AHFES International, 2024, p. 110–119. [En ligne]. Disponible : <https://doi.org/10.54941/ahfe.1004474>
- [5] S. S.-P. Côté *et al.*, “Sexual presence in virtual reality : A qeeg exploration,” dans *IEEE Conference on Virtual Reality and 3D User Interfaces Abstracts and Workshops (VRW)*. IEEE, 2024, p. 947–948. [En ligne]. Disponible : <https://doi.org/10.1109/VRW62533.2024.00270>
- [6] S. Marschall-Lévesque, J. L. Rouleau et P. Renaud, “Increasing valid profiles in phallometric assessment of sex offenders with child victims : Combining the strengths of audio stimuli and synthetic characters,” *Archives of Sexual Behavior*, vol. 47, n°. 2, p. 417–428, 2018. [En ligne]. Disponible : <https://doi.org/10.1007/s10508-017-1073-9>
- [7] N. Prause et E. Janssen, “Blood flow : vaginal photoplethysmography,” dans *Women’s Sexual Function and Dysfunction : Study, Diagnosis and Treatment*. Taylor & Francis, 2005, ch. 10.1, p. 359.
- [8] M. A. Guevara *et al.*, “Electroencephalographic correlates of sexual arousal induced by sexually-explicit reading in human females,” *Journal of Behavioral and Brain Science*, vol. 8, n°. 11, p. 599–614, 2018. [En ligne]. Disponible : <https://doi.org/10.4236/jbbs.2018.811037>
- [9] D. W. Prabowo *et al.*, “A systematic literature review of emotion recognition using eeg signals,” *Cognitive Systems Research*, vol. 80, p. 1–20, 2023.

- [10] S. Koelstra *et al.*, “Deap : A database for emotion analysis using physiological signals,” *IEEE Transactions on Affective Computing*, vol. 3, n°. 1, p. 18–31, 2012. [En ligne]. Disponible : <https://doi.org/10.1109/T-AFFC.2011.15>
- [11] P. Bashivan *et al.*, “Learning representations from eeg with deep recurrent-convolutional neural networks,” *arXiv preprint arXiv :1511.06448*, 2015.
- [12] V. J. Lawhern *et al.*, “Eegnet : a compact convolutional neural network for eeg-based brain–computer interfaces,” *Journal of neural engineering*, vol. 15, n°. 5, p. 056013, 2018.
- [13] T. Zhang *et al.*, “Spatial-temporal recurrent neural network for emotion recognition from eeg,” *IEEE Transactions on Cybernetics*, vol. 49, n°. 3, p. 839–847, 2018.
- [14] M. Ramzan et S. Dawn, “Fused cnn-lstm deep learning emotion recognition model using electroencephalography signals,” *International Journal of Neuroscience*, vol. 133, n°. 6, p. 587–597, 2021.
- [15] X. Chen *et al.*, “Eeg-based emotion recognition using an end-to-end regional-asymmetric convolutional neural network,” *Knowledge-Based Systems*, vol. 211, p. 106548, 2021. [En ligne]. Disponible : <https://www.sciencedirect.com/science/article/abs/pii/S0950705120304433>
- [16] J. Liu *et al.*, “Transformers for eeg emotion recognition,” *arXiv preprint arXiv :2110.06553*, 2021.
- [17] A. Esquivel, S. Nájera et M. García, “Analysis of eeg signal processing techniques based on spectrograms,” dans *Research in Computing Science*, vol. 145. IPN México, 2017, p. 65–76. [En ligne]. Disponible : https://rcs.cic.ipn.mx/2017_145/Analysis%20of%20EEG%20Signal%20Processing%20Techniques%20based%20on%20Spectrograms.pdf
- [18] R. J. Thomas et H. Sun, “Eeg spectrograms,” dans *Atlas of Sleep Medicine*. Springer, 2023, p. 299–305. [En ligne]. Disponible : https://link.springer.com/chapter/10.1007/978-3-031-34625-5_15
- [19] X. Li *et al.*, “Joint feature selection and classification for eeg-based emotion recognition,” *Knowledge-Based Systems*, vol. 210, p. 106963, 2020. [En ligne]. Disponible : <https://doi.org/10.1016/j.knosys.2020.106963>
- [20] M. W. Flood, “Entropyhub : An open-source toolkit for entropic time-series analysis,” <https://www.entropyhub.xyz>, 2024, version 2.0, disponible pour Python, MATLAB et Julia.

ANNEXE A INFÉRENCE DES MODÈLES GÉNÉRAUX ET RAFFINÉS SUR LES PARTICIPANTS TEST

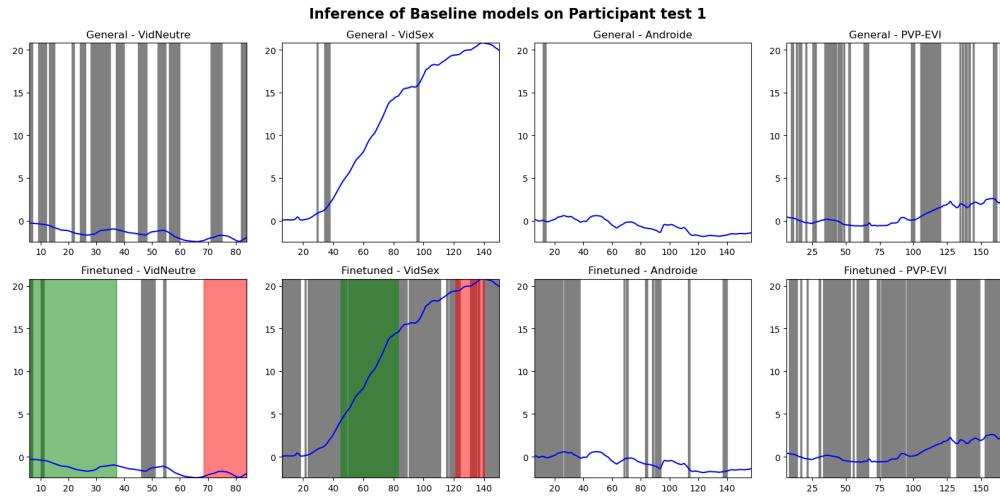


FIGURE A.1 Inférence du modèle `Fuzzy_MLP_Baseline_δθαβ` général et raffiné sur Participant test₁

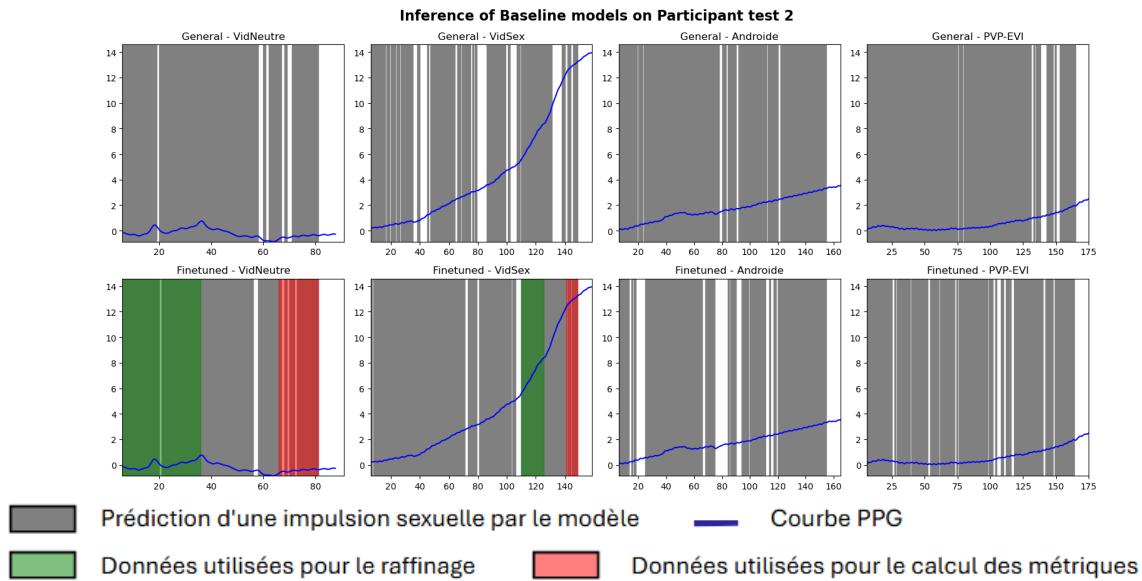


FIGURE A.2 Inférence du modèle `Fuzzy_MLP_Baseline_δθαβ` général et raffiné sur Participant test₂

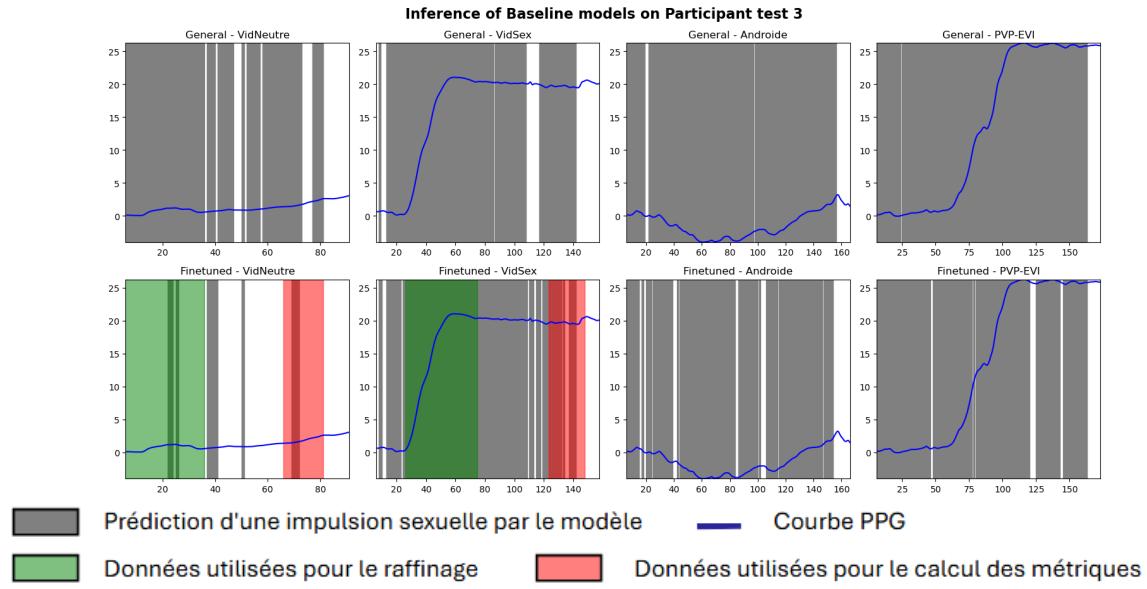


FIGURE A.3 Inférence du modèle `Fuzzy_MLP_Baseline_δθαβ` général et raffiné sur Participant test₃

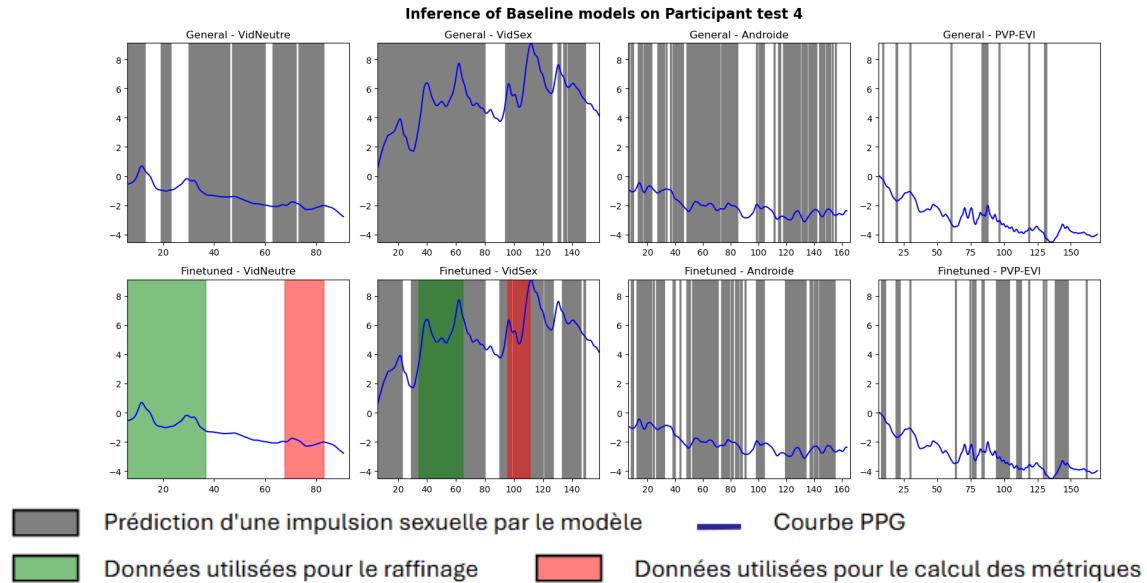


FIGURE A.4 Inférence du modèle `Fuzzy_MLP_Baseline_δθαβ` général et raffiné sur Participant test₄

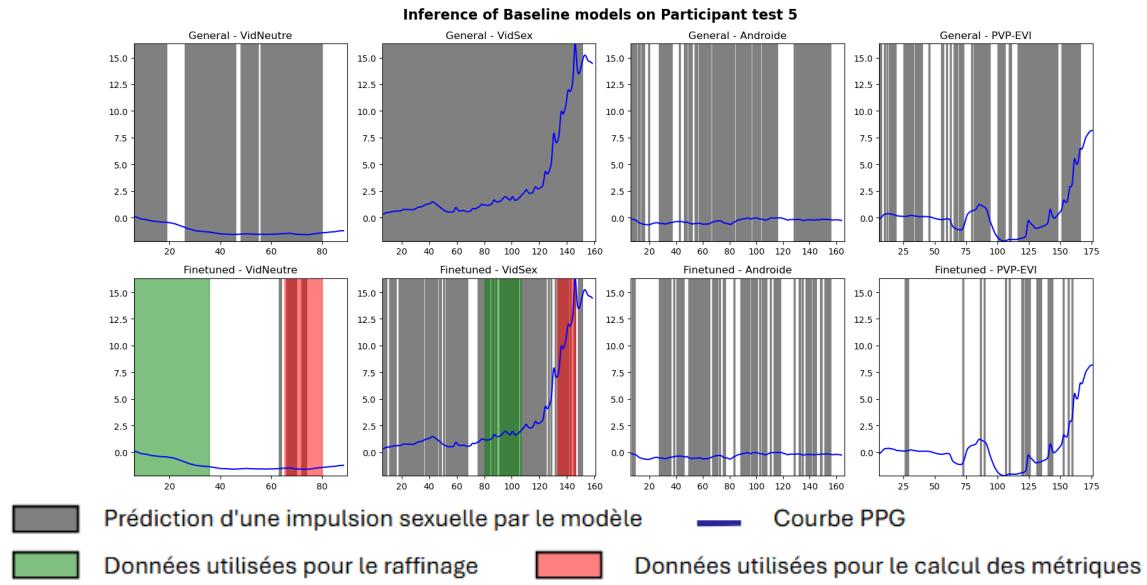


FIGURE A.5 Inférence du modèle `Fuzzy_MLP_Baseline_δθαβ` général et raffiné sur Participant test₅

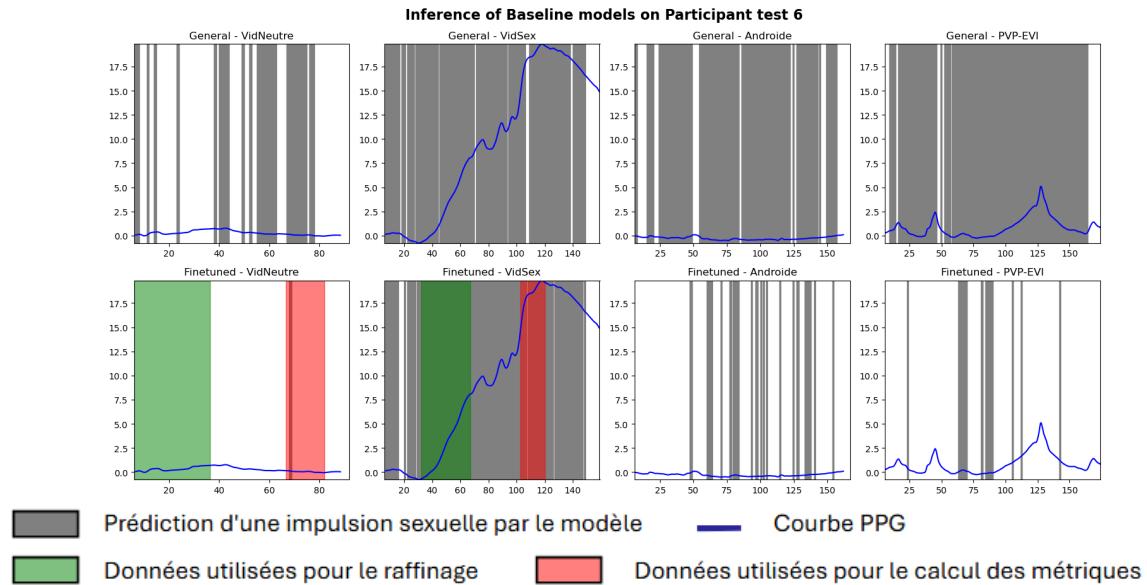


FIGURE A.6 Inférence du modèle `Fuzzy_MLP_Baseline_δθαβ` général et raffiné sur Participant test₆

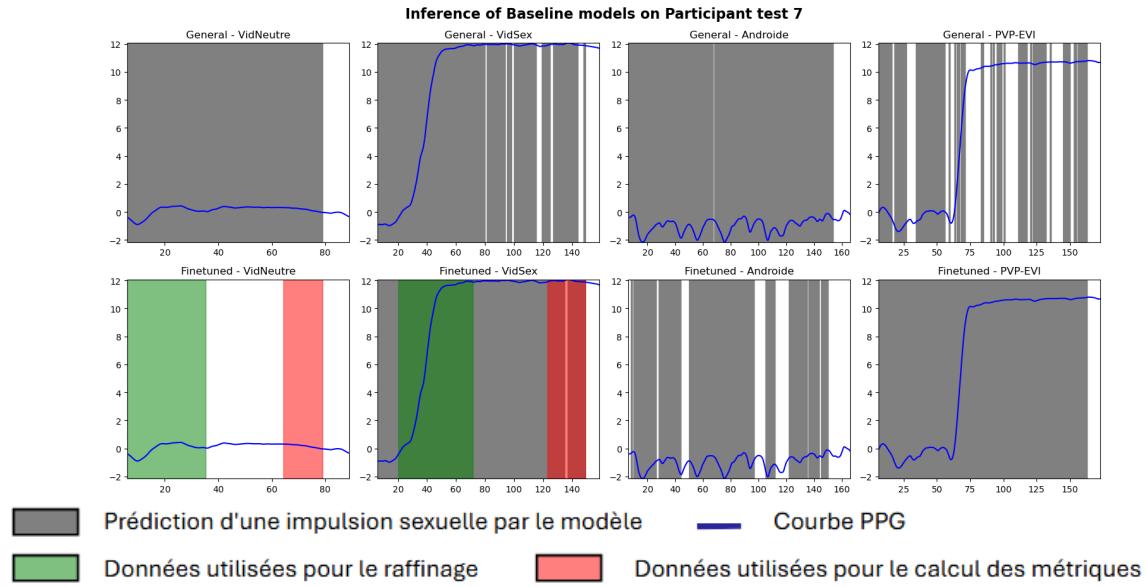


FIGURE A.7 Inférence du modèle `Fuzzy_MLP_Baseline_δθαβ` général et raffiné sur Participant test₇

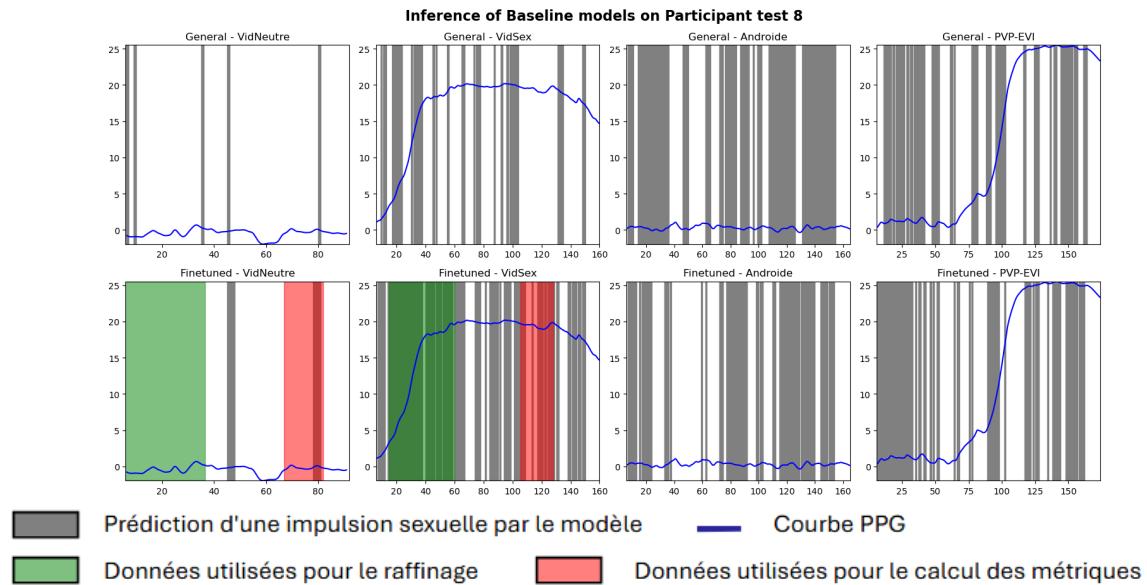


FIGURE A.8 Inférence du modèle `Fuzzy_MLP_Baseline_δθαβ` général et raffiné sur Participant test₈