



**RÉDUCTION DU NOMBRE D'ÉLECTRODES EEG POUR LA RECONNAISSANCE
DES ÉMOTIONS SANS PERTE SIGNIFICATIVE DE PERFORMANCE**

PAR ELHADJI MBAYE BITEYE

**MÉMOIRE PRÉSENTÉ À L'UNIVERSITÉ DU QUÉBEC À CHICOUTIMI COMME
EXIGENCE PARTIELLE EN VUE DE L'OBTENTION DU GRADE DE MAÎTRISE
ÈS SCIENCES (M. SC.) EN INFORMATIQUE**

QUÉBEC, CANADA

© ELHADJI MBAYE BITEYE, 2026

RÉSUMÉ

La reconnaissance automatique des émotions à partir de signaux électroencéphalographiques (EEG) constitue un domaine de recherche actif dans l'intelligence artificielle et l'interaction homme-machine. Les approches existantes reposent souvent sur des configurations denses d'électrodes afin de capter une information spatiale riche, mais cette densité entraîne des contraintes pratiques importantes liées au coût, au temps d'installation et à la complexité des systèmes EEG. La réduction du nombre d'électrodes tout en maintenant des performances de classification élevées représente ainsi un enjeu central pour le développement de systèmes plus compacts et plus facilement déployables.

Ce mémoire étudie l'impact de la réduction progressive du nombre d'électrodes sur la reconnaissance des émotions basée sur EEG. L'approche proposée s'appuie sur l'architecture EEGFormer, un modèle d'apprentissage profond intégrant un mécanisme d'attention permettant d'exploiter les relations spatiales entre les canaux EEG et d'identifier automatiquement les électrodes les plus informatives pour la classification de la valence.

Les expérimentations sont réalisées sur le jeu de données SEED (SJTU Emotion EEG Dataset), un ensemble de signaux EEG enregistrés auprès de plusieurs sujets exposés à des stimuli émotionnels. L'évaluation repose sur un protocole expérimental rigoureux incluant une validation croisée à 10 folds ainsi qu'un ensemble de test indépendant, afin d'assurer une estimation fiable et robuste des performances du modèle. Une analyse systématique de la réduction du nombre d'électrodes est menée en considérant plusieurs configurations successives (62, 48, 32, 16, 8, 6 et 4 électrodes). Les performances obtenues sont également comparées à celles de méthodes classiques de sélection d'électrodes.

Les résultats montrent qu'une réduction modérée du nombre d'électrodes peut être réalisée sans dégradation significative des performances de classification de la valence. En particulier, les configurations utilisant 32 et 16 électrodes obtiennent des résultats comparables à ceux de la configuration complète à 62 électrodes. Cette observation suggère que la suppression de certaines électrodes redondantes peut agir comme un mécanisme de régularisation structurelle et améliorer la stabilité du modèle.

Ces travaux démontrent ainsi qu'il est possible de concevoir des systèmes EEG plus compacts tout en conservant un niveau de performance élevé pour la prédiction de la valence émotionnelle.

TABLE DES MATIÈRES

RÉSUMÉ	ii
LISTE DES TABLEAUX	vii
LISTE DES FIGURES	viii
LISTE DES ABRÉVIATIONS	x
DÉDICACE	xi
REMERCIEMENTS	xii
AVANT-PROPOS	xiii
CHAPITRE I – INTRODUCTION	1
1.1 CONTEXTE GÉNÉRAL	1
1.2 PROBLÉMATIQUE DE LA RECHERCHE	2
1.3 QUESTIONS DE RECHERCHE	3
1.4 OBJECTIFS DE RECHERCHE	4
1.5 CONTRIBUTIONS SCIENTIFIQUES	5
1.6 ORGANISATION DU MÉMOIRE	6
CHAPITRE II – FONDEMENTS THÉORIQUES	8
2.1 ÉLECTROENCÉPHALOGRAPHIE (EEG)	8
2.1.1 PRINCIPES NEUROPHYSIOLOGIQUES	8
2.1.2 SYSTÈME INTERNATIONAL 10–20 ÉTENDU (10–10)	9
2.1.3 LIMITATIONS ET SOURCES DE BRUIT	10
2.2 MODÈLES DES ÉMOTIONS	12
2.2.1 MODÈLES CATÉGORIELS	12
2.2.2 MODÈLES DIMENSIONNELS (VALENCE–AROUSAL)	13
2.2.3 CORRÉLATS NEUROPHYSIOLOGIQUES DES ÉMOTIONS	14
2.3 DEEP LEARNING APPLIQUÉ À L’EEG	15
2.3.1 RÉSEAUX DE NEURONES CONVOLUTIONNELS (CNN)	16

2.3.2	RÉSEAUX RÉCURRENTS	17
2.3.3	TRANSFORMERS ET MODÉLISATION TEMPORELLE	18
2.3.4	MÉCANISMES D'ATTENTION	19
2.4	SÉLECTION DE VARIABLES ET RÉDUCTION DE CANAUX EEG	20
2.4.1	MÉTHODES DE FILTRAGE	22
2.4.2	MÉTHODES D'ENCAPSULATION	23
2.4.3	MÉTHODES BASÉES SUR L'APPRENTISSAGE	24
2.4.4	LIMITES THÉORIQUES DES APPROCHES EXISTANTES	25
2.5	MÉTRIQUES D'ÉVALUATION EN CLASSIFICATION	26
2.5.1	EXACTITUDE, PRÉCISION, RAPPEL ET SCORE F1	27
2.5.2	ROC-AUC	28
2.5.3	MATTHEWS CORRELATION COEFFICIENT (MCC)	29
CHAPITRE III – REVUE DES TRAVAUX CONNEXES		31
3.1	RECONNAISSANCE DES ÉMOTIONS À PARTIR DES SIGNAUX EEG	32
3.2	MÉTHODES TRADITIONNELLES DE RÉDUCTION ET DE SÉLECTION DES CANAUX EEG	33
3.3	MÉTHODES CLASSIQUES DE SÉLECTION DE CANAUX	36
3.3.1	MÉTHODE DE SÉLECTION BASÉE SUR RELIEFF	36
3.3.2	MÉTHODE MINIMUM REDUNDANCY MAXIMUM RELEVANCE	37
3.3.3	MÉTHODE SEQUENTIAL BACKWARD FLOATING SELECTION	38
3.4	APPROCHES BASÉES SUR L'APPRENTISSAGE PROFOND ET LES MÉ- CANISMES D'ATTENTION	39
CHAPITRE IV – MÉTHODOLOGIE PROPOSÉE		44
4.1	VUE D'ENSEMBLE DE L'APPROCHE	44
4.2	DESCRIPTION DU JEU DE DONNÉES SEED	46
4.2.1	STRUCTURE DES DONNÉES	47
4.2.2	JUSTIFICATION DU CHOIX DU JEU DE DONNÉES	48
4.3	PRÉTRAITEMENT DES SIGNAUX EEG	49

4.3.1	FENÊTRAGE TEMPOREL	49
4.3.2	CORRESPONDANCE SIGNAUX–LABELS	50
4.3.3	NORMALISATION ROBUSTE	50
4.3.4	PRÉVENTION DES FUITES DE DONNÉES	51
4.3.5	VALIDATION CROISÉE (STRATIFIED K-FOLD)	52
4.4	ARCHITECTURE DU MODÈLE EEGFORMER	53
4.4.1	REPRÉSENTATION D’ENTRÉE	54
4.4.2	MODULE D’ATTENTION SPATIALE	55
4.4.3	ENCODEUR TEMPOREL	55
4.4.4	MÉCANISME D’AUTO-ATTENTION	56
4.4.5	TÊTE DE CLASSIFICATION	57
4.5	STRATÉGIE DE RÉDUCTION D’ÉLECTRODES	57
4.5.1	EXTRACTION DES POIDS D’ATTENTION	58
4.5.2	CLASSEMENT DES ÉLECTRODES	59
4.5.3	CONSTRUCTION DES SOUS-ENSEMBLES ($62 \rightarrow 48 \rightarrow 32 \rightarrow 16 \rightarrow 8 \rightarrow 6 \rightarrow 4$)	60
4.6	JUSTIFICATION DES CHOIX MÉTHODOLOGIQUES	61
CHAPITRE V – EXPÉRIMENTATION ET RÉSULTATS		63
5.1	PROTOCOLE EXPÉRIMENTAL	63
5.1.1	STRATÉGIE DE SÉPARATION DES DONNÉES	63
5.1.2	VALIDATION CROISÉE	64
5.1.3	PARAMÈTRES D’ENTRAÎNEMENT	64
5.2	MÉTHODES DE COMPARAISON	66
5.2.1	MÉTHODE MINIMUM REDUNDANCY MAXIMUM RELEVANCE	67
5.2.2	MÉTHODE BASÉE SUR RELIEFF	67
5.2.3	MÉTHODE SEQUENTIAL BACKWARD FLOATING SELECTION	68
5.3	RÉSULTATS AVEC CONFIGURATION COMPLÈTE (62 ÉLECTRODES)	68
5.4	ANALYSE PROGRESSIVE DE LA RÉDUCTION	69

5.5	COMPARAISON AVEC LES MÉTHODES CLASSIQUES	73
5.6	ANALYSE DE ROBUSTESSE SOUS RÉDUCTION AGRESSIVE	76
5.7	ANALYSE DES POIDS D'ATTENTION ET INTERPRÉTABILITÉ	78
5.8	DISCUSSION DES RÉSULTATS	79
5.9	VALIDITÉ SCIENTIFIQUE ET MENACES À LA VALIDITÉ	81
CONCLUSION		83
BIBLIOGRAPHIE		85
APPENDICE A – RÉSULTATS DÉTAILLÉS DE LA VALIDATION CROISÉE ET COURBES D'APPRENTISSAGE		88
A.1	VALIDATION CROISÉE POUR 62 ÉLECTRODES	88
A.2	VALIDATION CROISÉE POUR 48 ÉLECTRODES	89
A.3	VALIDATION CROISÉE POUR 32 ÉLECTRODES	89
A.4	VALIDATION CROISÉE POUR 16 ÉLECTRODES	90
A.5	VALIDATION CROISÉE POUR 8 ÉLECTRODES	90
A.6	VALIDATION CROISÉE POUR 6 ÉLECTRODES	91
A.7	VALIDATION CROISÉE POUR 4 ÉLECTRODES	91
A.8	COURBES D'APPRENTISSAGE DU MODÈLE	92

LISTE DES TABLEAUX

TABLEAU 3.1 : Synthèse des travaux étudiés sur la réduction ou la sélection d'électrodes EEG	41
TABLEAU 5.1 : HYPERPARAMÈTRES UTILISÉS POUR L'ENTRAÎNEMENT DU MODÈLE EEGFORMER	66
TABLEAU 5.2 : PERFORMANCE DU MODÈLE EEGFORMER AVEC LA CONFIGURATION COMPLÈTE (62 ÉLECTRODES) SUR L'ENSEMBLE DE TEST (20%)	69
TABLEAU 5.3 : PERFORMANCE DU MODÈLE EEGFORMER POUR DIFFÉRENTES CONFIGURATIONS D'ÉLECTRODES SUR L'ENSEMBLE DE TEST (20%)	70
TABLEAU 5.4 : COMPARAISON DES PERFORMANCES SUR L'ENSEMBLE DE TEST SELON LES MÉTHODES DE SÉLECTION D'ÉLECTRODES	75
TABLEAU 5.5 : PERFORMANCES DU MODÈLE PAR VALIDATION CROISÉE (10 FOLDS) POUR DIFFÉRENTES CONFIGURATIONS D'ÉLECTRODES	77
TABLEAU A.1 : VALIDATION CROISÉE (10 FOLDS) POUR 62 ÉLECTRODES . .	88
TABLEAU A.2 : VALIDATION CROISÉE (10 FOLDS) POUR 48 ÉLECTRODES . .	89
TABLEAU A.3 : VALIDATION CROISÉE (10 FOLDS) POUR 32 ÉLECTRODES . .	89
TABLEAU A.4 : VALIDATION CROISÉE (10 FOLDS) POUR 16 ÉLECTRODES . .	90
TABLEAU A.5 : VALIDATION CROISÉE (10 FOLDS) POUR 8 ÉLECTRODES . . .	90
TABLEAU A.6 : VALIDATION CROISÉE (10 FOLDS) POUR 6 ÉLECTRODES . . .	91
TABLEAU A.7 : VALIDATION CROISÉE (10 FOLDS) POUR 4 ÉLECTRODES . . .	92

LISTE DES FIGURES

FIGURE 2.1 – DISTRIBUTION SPATIALE DES ÉLECTRODES EEG SELON LE SYSTÈME INTERNATIONAL 10–10.	10
FIGURE 2.2 – REPRÉSENTATION SIMPLIFIÉE DU MODÈLE DIMENSIONNEL VALENCE–AROUSAL	14
FIGURE 2.3 – PRINCIPALES CATÉGORIES DE MÉTHODES DE SÉLECTION DE VARIABLES APPLIQUÉES AUX SIGNAUX EEG.	22
FIGURE 4.1 – PIPELINE DE L’APPROCHE PROPOSÉE POUR LA PRÉDICTION DE LA VALENCE À PARTIR DES SIGNAUX EEG.	46
FIGURE 4.2 – ARCHITECTURE DU MODÈLE EEGFORMER.	53
FIGURE 4.3 – DISTRIBUTION DES POIDS D’ATTENTION NORMALISÉS POUR LES 62 ÉLECTRODES, TRIÉES PAR ORDRE DÉCROISSANT D’IMPORTANCE.	60
FIGURE 5.1 – CONFIGURATIONS D’ÉLECTRODES SÉLECTIONNÉES PAR LE MODÈLE EEGFORMER POUR DIFFÉRENTES TAILLES DE SOUS-ENSEMBLES.	72
FIGURE A.1 – COURBES D’APPRENTISSAGE DU MODÈLE EEGFORMER POUR LA CONFIGURATION À 62 ÉLECTRODES.	93
FIGURE A.2 – COURBES D’APPRENTISSAGE DU MODÈLE EEGFORMER POUR LA CONFIGURATION À 48 ÉLECTRODES.	93
FIGURE A.3 – COURBES D’APPRENTISSAGE DU MODÈLE EEGFORMER POUR LA CONFIGURATION À 32 ÉLECTRODES.	94
FIGURE A.4 – COURBES D’APPRENTISSAGE DU MODÈLE EEGFORMER POUR LA CONFIGURATION À 16 ÉLECTRODES.	94
FIGURE A.5 – COURBES D’APPRENTISSAGE DU MODÈLE EEGFORMER POUR LA CONFIGURATION À 8 ÉLECTRODES.	95
FIGURE A.6 – COURBES D’APPRENTISSAGE DU MODÈLE EEGFORMER POUR LA CONFIGURATION À 6 ÉLECTRODES.	95

FIGURE A.7 – COURBES D'APPRENTISSAGE DU MODÈLE EEGFORMER POUR LA CONFIGURATION À 4 ÉLECTRODES.	96
---	----

LISTE DES ABRÉVIATIONS

EEG	Électroencéphalographie
SEED	SJTU Emotion EEG Dataset
ML	Machine Learning
DL	Deep Learning
CNN	Convolutional Neural Network
RNN	Recurrent Neural Network
LSTM	Long Short-Term Memory
mRMR	Minimum Redundancy Maximum Relevance
SBFS	Sequential Backward Floating Selection
SFS	Sequential Forward Selection
SBS	Sequential Backward Selection
ROC-AUC	Area Under the Receiver Operating Characteristic Curve
MCC	Matthews Correlation Coefficient
F1	Score F1
XAI	Explainable Artificial Intelligence

DÉDICACE

À mes chers parents,

Je vous dédie ce travail en témoignage de mon amour, de ma reconnaissance et de mon profond respect. Votre soutien, vos sacrifices et les valeurs que vous m'avez transmises ont toujours été une source de motivation dans mon parcours.

Je rends grâce à Dieu pour m'avoir accordé la force et la patience nécessaires pour mener ce travail à terme.

À la mémoire de mon défunt père, dont l'exemple et les conseils continueront toujours d'éclairer mon chemin.

À ma mère, pour son amour, son soutien indéfectible et ses sacrifices.

À mes sœurs et à mes frères, pour leurs encouragements et leur affection.

REMERCIEMENTS

Je tiens tout d'abord à rendre grâce à Dieu, le Tout-Puissant, pour m'avoir donné la force, la patience et la persévérance nécessaires afin de mener à bien ce travail.

Je souhaite exprimer ma profonde gratitude à mon directeur de recherche, le professeur Hamdi Ben Abdessalem, pour son encadrement, ses précieux conseils et sa grande disponibilité tout au long de la réalisation de ce mémoire. Sa rigueur scientifique, son soutien constant et la confiance qu'il m'a accordée ont été essentiels à l'aboutissement de ce travail.

Mes sincères remerciements s'adressent également à ma codirectrice de recherche, la professeure Haïfa Nakouri, pour son accompagnement, ses suggestions pertinentes et son engagement tout au long de ce projet. Sa disponibilité et ses conseils avisés ont grandement contribué à l'amélioration de ce travail.

Je tiens également à remercier l'Université du Québec à Chicoutimi et le département d'informatique pour l'environnement académique stimulant et les ressources mises à disposition durant ma formation.

Enfin, je souhaite exprimer ma profonde reconnaissance à ma famille pour leur soutien constant et leurs encouragements tout au long de mon parcours.

Je tiens à adresser un remerciement tout particulier à ma mère, pour son amour inconditionnel, sa patience et les nombreux sacrifices qu'elle a consentis pour moi. Son soutien indéfectible, ses prières et sa confiance ont été une source permanente de motivation et de force dans les moments les plus exigeants de ce parcours.

Je remercie également mes adorables grandes sœurs et mes deux grands frères pour leur présence et leurs encouragements. J'ai enfin une pensée toute particulière pour la mémoire de mon défunt père, dont les valeurs et les enseignements continuent de m'inspirer chaque jour.

À toutes les personnes qui, de près ou de loin, ont contribué à la réalisation de ce mémoire, je tiens à adresser mes sincères remerciements.

AVANT-PROPOS

L'essor récent de l'intelligence artificielle et des technologies d'analyse des signaux cérébraux a suscité un intérêt croissant pour la reconnaissance automatique des émotions à partir de signaux électroencéphalographiques (EEG). Dans ce contexte, la question de la conception de systèmes EEG à la fois performants et facilement déployables dans des situations réelles constitue un enjeu important pour la recherche actuelle.

C'est dans cette perspective que s'inscrit le présent mémoire. L'intérêt pour ce sujet est né du constat que de nombreuses approches de reconnaissance des émotions reposent sur des configurations EEG très denses, impliquant plusieurs dizaines d'électrodes. Bien que ces configurations permettent de capturer une information cérébrale riche, elles introduisent également des contraintes importantes liées au coût du matériel, au temps d'installation et au confort de l'utilisateur.

Le présent travail vise ainsi à explorer la possibilité de réduire le nombre d'électrodes nécessaires à la reconnaissance des émotions tout en conservant un niveau de performance satisfaisant. Pour cela, l'étude s'appuie sur l'architecture EEGFormer et analyse l'impact d'une réduction progressive du nombre d'électrodes dans un cadre expérimental cohérent et reproductible.

L'ampleur de cette recherche se limite à une analyse expérimentale réalisée sur le jeu de données SEED, largement utilisé dans la littérature pour l'étude de la reconnaissance des émotions basée sur EEG. Les résultats obtenus doivent donc être interprétés dans le contexte de ce cadre expérimental spécifique.

Ce mémoire s'inscrit ainsi dans une démarche visant à mieux comprendre le compromis entre compacité des systèmes EEG et performance de classification, tout en contribuant à la réflexion sur le développement de solutions EEG plus légères et plus facilement déployables dans des applications réelles.

CHAPITRE I

INTRODUCTION

1.1 CONTEXTE GÉNÉRAL

Au cours des dernières années, la reconnaissance automatique des émotions a suscité un intérêt croissant dans plusieurs domaines tels que l'intelligence artificielle, l'interaction homme-machine, la santé mentale et les systèmes adaptatifs intelligents. Comprendre et détecter les états émotionnels humains permet de concevoir des technologies plus sensibles, personnalisées et réactives aux besoins des utilisateurs.

Parmi les différentes modalités utilisées pour l'analyse des émotions, l'électroencéphalographie (EEG) occupe une place particulière. Contrairement à des signaux comportementaux externes, l'EEG permet d'accéder plus directement à la dynamique cérébrale et fournit une mesure à haute résolution temporelle, ce qui le rend pertinent pour modéliser des états affectifs. Dans la littérature, de nombreuses études ont ainsi exploré des approches d'apprentissage automatique et d'apprentissage profond pour améliorer la fiabilité de la reconnaissance des émotions basée sur EEG ([Vafaei et al., 2024](#); [Wan et al., 2023](#)).

Cependant, une partie importante des travaux existants s'appuie sur des configurations denses (plusieurs dizaines d'électrodes) afin de capter une information spatiale riche. Cette densité a un coût : elle augmente la complexité matérielle, le temps d'installation, l'inconfort et les exigences de calcul, ce qui freine le déploiement de solutions EEG en conditions réelles et dans des systèmes portables ([Vafaei et al., 2024](#)).

Dans ce contexte, la réduction du nombre d'électrodes tout en conservant une performance comparable constitue un enjeu majeur. Plusieurs méthodes classiques de sélection

(filtres, wrappers) ont été proposées, mais les comparaisons restent parfois difficiles lorsque les protocoles expérimentaux ne sont pas homogènes. Plus récemment, des approches basées sur l'attention ont montré un potentiel intéressant, notamment en apprenant l'importance relative des canaux au sein du modèle (Tong *et al.*, 2023; Wan *et al.*, 2023).

Enfin, l'évaluation de stratégies de réduction nécessite des jeux de données de référence bien établis. Le jeu de données SEED, largement utilisé en reconnaissance des émotions basée sur EEG, fournit une configuration dense (62 canaux) adaptée à l'étude systématique de sous-ensembles d'électrodes (Zheng & Lu, 2015). Le présent mémoire s'inscrit dans cette problématique et vise à analyser une réduction progressive du nombre d'électrodes tout en évitant une perte significative de performance.

1.2 PROBLÉMATIQUE DE LA RECHERCHE

Malgré les avancées significatives en reconnaissance des émotions basée sur l'EEG, une dépendance importante aux configurations denses d'électrodes persiste dans la littérature. L'utilisation de 32, 62 voire davantage de canaux permet de capter une information spatiale riche, mais introduit simultanément des contraintes pratiques importantes : augmentation des coûts matériels, complexité d'installation, inconfort pour l'utilisateur et charge computationnelle accrue.

Plusieurs travaux ont démontré qu'une réduction du nombre d'électrodes est envisageable sans dégradation majeure des performances (Vafaei *et al.*, 2024; Qu *et al.*, 2024). Toutefois, ces études reposent souvent sur des méthodes classiques de sélection appliquées dans des cadres expérimentaux hétérogènes, rendant les comparaisons difficiles. De plus, les stratégies basées sur l'apprentissage profond exploitent généralement l'ensemble des canaux

disponibles, sans intégrer explicitement un mécanisme de sélection ou de hiérarchisation spatiale.

Ainsi, une question centrale demeure : est-il possible de réduire significativement le nombre d'électrodes EEG tout en conservant un niveau de performance comparable, dans un cadre expérimental rigoureux et cohérent ?

Cette problématique soulève également un enjeu méthodologique. Les comparaisons entre méthodes classiques de sélection (Minimum Redundancy Maximum Relevance (mRMR), ReliefF, SBFS (Sequential Backward Feature Selection)) et des approches basées sur l'attention sont rarement réalisées sous des conditions strictement identiques, ce qui limite la portée des conclusions. Une évaluation unifiée, intégrant plusieurs niveaux de réduction progressive, apparaît donc nécessaire pour analyser de manière fiable le compromis entre la compacité du système et la robustesse de la classification.

Le présent mémoire s'inscrit dans cette perspective et vise à apporter une analyse systématique de la réduction d'électrodes EEG pour la prédiction de la valence à partir des signaux EEG, en s'appuyant sur une architecture basée sur les mécanismes d'attention et sur un protocole expérimental homogène.

1.3 QUESTIONS DE RECHERCHE

À partir de la problématique identifiée, ce mémoire vise à analyser de manière systématique l'impact de la réduction du nombre d'électrodes EEG sur la performance des modèles de reconnaissance des émotions. Il s'agit notamment d'examiner dans quelle mesure cette réduction peut être réalisée sans compromettre la qualité des prédictions, ainsi que d'identifier les limites associées à cette simplification. Dans ce contexte, les questions de recherche suivantes sont formulées :

- Q1.** Est-il possible de réduire le nombre d'électrodes EEG tout en maintenant une performance fiable pour la prédiction de la valence dans la reconnaissance des émotions ?
- Q2.** Si une réduction est possible, quel est le nombre minimal d'électrodes permettant de conserver une performance comparable à celle obtenue avec une configuration EEG complète ?
- Q3.** Certaines électrodes apportent-elles davantage de bruit que d'information pour la prédiction de la valence, et leur suppression peut-elle améliorer la stabilité et les performances du modèle ?

1.4 OBJECTIFS DE RECHERCHE

L'objectif principal de ce mémoire est d'évaluer la possibilité de réduire significativement le nombre d'électrodes utilisées pour la prédiction de la valence à partir des signaux EEG, tout en maintenant un niveau de performance comparable à celui obtenu avec la configuration complète.

Pour atteindre cet objectif, plusieurs objectifs spécifiques sont définis. Il s'agit d'abord de mettre en place un protocole expérimental unifié permettant de comparer différentes stratégies de sélection d'électrodes dans des conditions strictement identiques. Le travail consiste également à implémenter et évaluer des méthodes classiques de sélection, telles que le mRMR, ReliefF et le SBFS, dans le cadre de la prédiction de la valence à partir du jeu de données SEED.

Par ailleurs, ce mémoire vise à intégrer un mécanisme d'attention au sein de l'architecture EEGFormer afin d'apprendre automatiquement l'importance relative des électrodes. Une analyse progressive de plusieurs configurations réduites (48, 32, 16, 8, 6 et 4 électrodes) est ensuite réalisée afin d'évaluer leur impact sur la performance et la capacité de généralisation

du modèle. Enfin, l'étude cherche à analyser le compromis entre la compacité du système, la robustesse des performances et la cohérence spatiale des électrodes sélectionnées.

1.5 CONTRIBUTIONS SCIENTIFIQUES

À partir de la problématique identifiée et des objectifs formulés précédemment, ce mémoire propose une contribution scientifique visant à concilier performance de classification de la valence et réduction matérielle dans les systèmes de reconnaissance des émotions basés sur l'EEG.

Notre approche se distingue par l'intégration d'un mécanisme d'attention directement au sein de l'architecture EEGFormer afin d'identifier automatiquement les électrodes les plus discriminantes, sans recourir exclusivement à des méthodes externes de sélection de variables.

Les principales contributions de ce travail sont les suivantes :

- Proposition d'un cadre expérimental unifié permettant de comparer équitablement des méthodes classiques de sélection d'électrodes (mRMR, ReliefF et SBFS) avec une approche basée sur un mécanisme d'attention intégré dans un modèle Transformer.
- Mise en œuvre d'une analyse systématique de la réduction progressive du nombre d'électrodes EEG ($62 \rightarrow 48 \rightarrow 32 \rightarrow 16 \rightarrow 8 \rightarrow 6 \rightarrow 4$), afin d'évaluer précisément le compromis entre compacité du système et performance de classification.
- Démonstration expérimentale qu'une réduction modérée du nombre d'électrodes (notamment à 32 ou 16 canaux) peut maintenir, voire améliorer, la performance par rapport à la configuration complète, suggérant un effet de régularisation structurelle.
- Analyse interprétable des poids d'attention permettant d'identifier les régions cérébrales les plus contributives à la classification de la valence.

- Contribution pratique à la conception de systèmes EEG plus légers, plus rapides à déployer et potentiellement plus adaptés aux applications réelles et portables.

Cette recherche apporte ainsi une contribution méthodologique et expérimentale au domaine de la reconnaissance des émotions basée sur l’EEG, en proposant une stratégie intégrée d’optimisation du nombre d’électrodes tout en préservant la robustesse du modèle.

1.6 ORGANISATION DU MÉMOIRE

Ce mémoire est structuré en six chapitres, chacun contribuant de manière progressive à l’analyse et à la résolution de la problématique liée à la réduction du nombre d’électrodes dans les systèmes de reconnaissance des émotions basés sur l’EEG.

Le Chapitre II présente les fondements théoriques nécessaires à la compréhension du sujet. Il introduit les principes de l’électroencéphalographie, les modèles des émotions, les approches d’apprentissage profond appliquées aux signaux EEG ainsi que les méthodes classiques de sélection de variables et les principales métriques d’évaluation en classification.

Le Chapitre III propose une revue des travaux connexes. Les études existantes sur la reconnaissance des émotions basée sur EEG, la réduction du nombre d’électrodes et les approches basées sur l’attention y sont analysées afin d’identifier les limites actuelles et le gap scientifique que ce mémoire cherche à combler.

Le Chapitre IV décrit en détail la méthodologie proposée. Il présente le jeu de données SEED, les étapes de prétraitement, l’architecture EEGFormer, la stratégie de réduction progressive des électrodes ainsi que les méthodes de comparaison retenues.

Le Chapitre V expose le protocole expérimental et les résultats obtenus. Une analyse progressive de la réduction des électrodes est réalisée, suivie d'une comparaison avec les méthodes classiques et d'une discussion critique des performances observées.

Enfin, le Chapitre VI conclut le mémoire en synthétisant les principales contributions, en discutant les limites de l'étude et en proposant des perspectives de recherche futures.

CHAPITRE II

FONDEMENTS THÉORIQUES

2.1 ÉLECTROENCÉPHALOGRAPHIE (EEG)

Dans ce travail, l'analyse des émotions repose sur l'exploitation de signaux EEG. Avant d'aborder les aspects liés au traitement et à la modélisation de ces données, il est important de présenter brièvement les principes de base de cette technique, ainsi que les éléments nécessaires à la compréhension de son utilisation dans ce contexte.

2.1.1 PRINCIPES NEUROPHYSIOLOGIQUES

L'EEG repose sur l'enregistrement de l'activité électrique générée par les neurones du cortex cérébral. Plus précisément, les électrodes placées sur le cuir chevelu captent les variations de potentiel résultant principalement des potentiels postsynaptiques synchronisés de larges populations neuronales. Ces variations reflètent l'activité collective de milliers, voire de millions de neurones, plutôt que l'activité d'une cellule isolée.

L'EEG mesure donc une activité macroscopique, sensible à la synchronisation neuronale. Cette propriété explique en partie sa très haute résolution temporelle, qui permet d'observer des dynamiques cérébrales de l'ordre de la milliseconde. En revanche, la localisation spatiale précise des sources reste plus limitée que dans des techniques comme l'imagerie par résonance magnétique fonctionnelle (fMRI).

L'activité EEG est généralement analysée selon différentes bandes fréquentielles (delta, theta, alpha, beta, gamma), chacune étant associée à des fonctions cognitives et affectives spécifiques. Plusieurs travaux ont montré que certaines bandes et certaines régions corticales

jouent un rôle important dans la discrimination des états émotionnels (Zheng & Lu, 2015). Cette organisation spatiale et fréquentielle constitue l'un des fondements théoriques de la sélection et de la réduction d'électrodes.

Dans le contexte de la reconnaissance des émotions, les variations d'activité au niveau des régions frontales, temporales et pariétales sont fréquemment étudiées. Toutefois, toutes les électrodes ne contribuent pas de manière équivalente à la classification. Cette observation ouvre la voie à des stratégies visant à identifier les canaux les plus informatifs, afin de réduire la redondance spatiale sans compromettre la performance du système.

2.1.2 SYSTÈME INTERNATIONAL 10–20 ÉTENDU (10–10)

La localisation des électrodes EEG repose sur des conventions normalisées permettant d'assurer une reproductibilité des mesures et une cohérence entre les études. Le système international 10–20 constitue la référence historique pour le positionnement des électrodes sur le cuir chevelu. Il repose sur des distances proportionnelles (10 % ou 20 %) entre des repères anatomiques standardisés, notamment le nasion, l'inion et les points préauriculaires.

Avec l'évolution des dispositifs EEG et l'augmentation du nombre de canaux disponibles, une extension de ce système a été proposée : le système 10–10. Cette configuration densifie le maillage spatial en insérant des électrodes intermédiaires entre les positions du 10–20 classique. Elle permet ainsi une meilleure résolution spatiale et une couverture plus fine des régions corticales.

Le dataset SEED utilisé dans ce mémoire adopte une configuration à 62 électrodes basée sur le système 10–20 étendu (10–10). Cette densité élevée rend possible l'étude systématique de sous-ensembles d'électrodes dans le cadre d'une réduction progressive des canaux.

La figure 2.1 illustre la distribution spatiale des électrodes selon le système international 10–10, mettant en évidence l’extension du maillage par rapport au système 10–20 standard.




FIGURE 2.1 : Distribution spatiale des électrodes EEG selon le système international 10–10.

Source : figure adaptée et modifiée par l’auteur à partir d’une image issue de Wikimedia Commons (licence Creative Commons).

Cette organisation spatiale structurée est essentielle pour l’analyse des signaux EEG, car elle permet d’associer les électrodes à des régions cérébrales spécifiques (frontale, pariétale, temporelle, occipitale). Dans le contexte de la reconnaissance des émotions, certaines régions, notamment frontales et temporelles, jouent un rôle particulièrement important dans le traitement des états affectifs.

2.1.3 LIMITATIONS ET SOURCES DE BRUIT

Malgré sa richesse informationnelle et sa haute résolution temporelle, l’électroencéphalographie présente plusieurs limitations inhérentes à sa nature de mesure non invasive.

Ces contraintes doivent être prises en compte lors de l'interprétation des signaux et de la conception de modèles d'apprentissage automatique.

Premièrement, l'EEG possède une résolution spatiale limitée. Les signaux enregistrés au niveau du cuir chevelu résultent de l'activité synchrone de larges populations neuronales, ce qui entraîne un phénomène de diffusion volumique (*volume conduction*). Cette propriété rend parfois difficile l'identification précise de la source corticale d'une activité mesurée.

Deuxièmement, les signaux EEG sont fortement sensibles aux artefacts. Parmi les principales sources de bruit, on retrouve les mouvements oculaires (EOG), l'activité musculaire (EMG), les interférences électriques externes, ainsi que les mouvements de la tête ou des électrodes.

Ces perturbations peuvent masquer l'information neuronale pertinente et introduire des variations non liées aux états émotionnels étudiés. Un prétraitement rigoureux (filtrage, suppression d'artefacts, normalisation) est donc essentiel avant toute phase d'apprentissage.

Enfin, la variabilité inter-sujets constitue un défi majeur en reconnaissance des émotions basée sur EEG. Les réponses cérébrales aux stimuli émotionnels peuvent varier significativement d'un individu à l'autre, ce qui complique la généralisation des modèles. Cette variabilité justifie l'utilisation de protocoles expérimentaux stricts et de mécanismes favorisant la robustesse du modèle.

Ces limitations soulignent l'importance d'une approche méthodologique rigoureuse, combinant prétraitement adapté, sélection pertinente des électrodes et architecture d'apprentissage robuste, afin d'extraire des représentations fiables des états émotionnels.

2.2 MODÈLES DES ÉMOTIONS

La modélisation des émotions constitue une étape essentielle dans les systèmes de reconnaissance affective. Avant d'analyser les signaux EEG et d'entraîner des modèles d'apprentissage automatique, il est nécessaire de définir un cadre conceptuel permettant de représenter les états émotionnels humains. Dans la littérature, deux grandes approches sont généralement utilisées pour structurer les émotions : les modèles catégoriels et les modèles dimensionnels. Ces deux perspectives offrent des représentations complémentaires des états affectifs et influencent directement la manière dont les tâches de classification sont formulées.

2.2.1 MODÈLES CATÉGORIELS

Les modèles catégoriels représentent les émotions comme un ensemble de catégories distinctes et relativement indépendantes. Selon cette approche, certaines émotions fondamentales possèdent des caractéristiques physiologiques et comportementales spécifiques. Parmi les travaux les plus influents dans ce domaine figurent ceux de Paul Ekman, qui a identifié six émotions de base : la joie, la tristesse, la peur, la colère, la surprise et le dégoût. Ces émotions seraient universellement reconnaissables à travers différentes cultures, notamment par leurs expressions faciales caractéristiques.

Dans les systèmes de reconnaissance automatique des émotions, les modèles catégoriels conduisent généralement à des tâches de classification discrète. Chaque segment de signal est associé à une catégorie émotionnelle spécifique, ce qui permet de formuler le problème comme une classification multi-classes.

Dans le contexte de ce mémoire, le dataset SEED adopte une catégorisation émotionnelle en trois classes : positive, neutre et négative. Cette organisation correspond à une représentation

catégorielle simplifiée des états affectifs et permet d'entraîner des modèles de classification supervisée à partir des signaux EEG.

2.2.2 MODÈLES DIMENSIONNELS (VALENCE–AROUSAL)

Contrairement aux modèles catégoriels, les modèles dimensionnels représentent les émotions dans un espace continu défini par plusieurs dimensions psychologiques. L'approche la plus répandue repose sur deux axes principaux : la valence et l'arousal.

La valence correspond au caractère agréable ou désagréable d'un état émotionnel, tandis que l'arousal décrit le niveau d'activation physiologique associé à cette émotion. Ensemble, ces deux dimensions permettent de positionner différents états affectifs dans un espace bidimensionnel continu.

Par exemple, la joie est généralement associée à une valence positive et à un arousal élevé, tandis que la tristesse correspond à une valence négative et à un niveau d'activation plus faible. Cette représentation dimensionnelle permet de modéliser plus finement les transitions émotionnelles et les variations d'intensité des états affectifs.

La figure 2.2 illustre une représentation simplifiée du modèle dimensionnel valence–arousal.




FIGURE 2.2 : Représentation simplifiée du modèle dimensionnel valence–arousal

Bien que ce modèle repose sur une représentation continue des émotions, le dataset SEED utilisé dans ce mémoire adopte une catégorisation discrète en trois classes (positive, neutre et négative). Cette organisation peut être interprétée comme une discrétisation de la dimension de valence, sans prise en compte explicite de la dimension d’arousal.

Dans ce travail, la tâche étudiée correspond donc à une classification discrète de la valence émotionnelle à partir des signaux EEG.

2.2.3 CORRÉLATS NEUROPHYSIOLOGIQUES DES ÉMOTIONS

Les émotions humaines ne se manifestent pas uniquement par des comportements observables ou par une expérience subjective. Elles s’accompagnent également de modifications mesurables de l’activité cérébrale. L’étude de ces corrélats neurophysiologiques permet de mieux comprendre comment les états émotionnels peuvent être détectés à partir de signaux cérébraux tels que l’électroencéphalographie (EEG).

Dans le domaine de la reconnaissance des émotions basée sur l'EEG, plusieurs travaux ont montré que certaines régions corticales contribuent davantage à la discrimination des états émotionnels. En particulier, l'activité enregistrée dans les régions frontales et temporales est souvent associée à des variations liées aux émotions. Ces observations suggèrent que certaines positions d'électrodes contiennent des informations plus pertinentes pour la classification des états émotionnels (Zheng & Lu, 2015).

Par ailleurs, l'analyse des signaux EEG a également mis en évidence que différentes bandes de fréquences peuvent être impliquées dans la caractérisation des émotions. L'étude de ces composantes fréquentielles, combinée à l'analyse spatiale des électrodes, permet d'identifier les canaux les plus informatifs pour la reconnaissance des émotions.

Ces résultats expliquent pourquoi de nombreuses recherches s'intéressent aujourd'hui à la réduction du nombre d'électrodes EEG tout en conservant des performances de classification satisfaisantes. Identifier les électrodes les plus discriminantes permet non seulement de simplifier les systèmes EEG, mais aussi de mieux comprendre quelles régions cérébrales contribuent le plus à la reconnaissance des états émotionnels (Zheng & Lu, 2015; Vafaei *et al.*, 2024).

Dans cette perspective, la sélection ou la réduction d'électrodes constitue une étape importante pour concevoir des systèmes de reconnaissance des émotions plus efficaces et plus adaptés aux applications réelles.

2.3 DEEP LEARNING APPLIQUÉ À L'EEG

Dans le cadre de l'analyse des signaux EEG, les approches d'apprentissage profond occupent aujourd'hui une place importante. Elles permettent d'extraire automatiquement des représentations pertinentes à partir de données complexes et multicanales. Cette section

présente les principales architectures d'apprentissage profond utilisées pour le traitement des signaux EEG dans le contexte de la reconnaissance des émotions.

2.3.1 RÉSEAUX DE NEURONES CONVOLUTIONNELS (CNN)

Les réseaux de neurones convolutionnels (Convolutional Neural Networks – CNN) font partie des architectures d'apprentissage profond les plus utilisées pour analyser des données structurées. Leur idée centrale est d'apprendre automatiquement des motifs pertinents à partir des données, grâce à des filtres de convolution qui détectent progressivement des structures de plus en plus discriminantes.

Dans le cas des signaux EEG, les CNN sont souvent utilisés car ils peuvent exploiter l'organisation multicanale des enregistrements. Chaque électrode capte une activité issue d'une région différente du cuir chevelu, et les convolutions permettent d'apprendre des représentations qui combinent ces informations de manière structurée. Dans la littérature, l'apprentissage profond a montré sa capacité à extraire des caractéristiques utiles pour des tâches de reconnaissance des émotions à partir de l'EEG, notamment sur des jeux de données de référence comme SEED ([Zheng & Lu, 2015](#)).

Cependant, l'utilisation d'architectures profondes sur des configurations EEG denses (par exemple plusieurs dizaines d'électrodes) entraîne généralement une augmentation de la dimension d'entrée, du coût de calcul et du risque de redondance entre canaux. Cette réalité motive l'étude de stratégies visant à réduire le nombre d'électrodes tout en conservant une performance de classification satisfaisante, ce qui constitue un axe central de la recherche récente en EEG et en reconnaissance des émotions ([Vafaei *et al.*, 2024](#)).

Enfin, même si les CNN sont efficaces pour apprendre des motifs locaux, ils peuvent être moins adaptés lorsqu'il s'agit de modéliser des dépendances globales et complexes entre

différentes régions du cerveau. Cette limitation a contribué à l'émergence d'architectures basées sur l'attention et les Transformers, capables de capturer des interactions plus riches à l'échelle spatiale et temporelle. Ces approches sont présentées dans les sous-sections suivantes.

2.3.2 RÉSEAUX RÉCURRENTS

Les réseaux de neurones récurrents (Recurrent Neural Networks – RNN) constituent une autre famille importante d'architectures d'apprentissage profond utilisées pour l'analyse de données séquentielles. Contrairement aux réseaux de neurones classiques, les RNN sont conçus pour prendre en compte les dépendances temporelles présentes dans les données. Ils possèdent des connexions récurrentes qui permettent de conserver une mémoire des informations précédemment observées dans la séquence.

Dans le contexte des signaux EEG, cette propriété est particulièrement intéressante, car les enregistrements cérébraux sont intrinsèquement temporels. Les variations d'activité neuronale évoluent au cours du temps et certaines dynamiques temporelles peuvent contenir des informations importantes pour la reconnaissance des états émotionnels.

Cependant, les RNN classiques souffrent souvent de difficultés d'apprentissage lorsqu'il s'agit de modéliser des dépendances temporelles longues. Pour surmonter ces limitations, des variantes plus avancées ont été proposées, notamment les réseaux Long Short-Term Memory (LSTM). Les LSTM introduisent des mécanismes de portes permettant de contrôler le flux d'information et de mieux préserver les dépendances à long terme dans les séquences.

Dans l'analyse des signaux EEG, les architectures LSTM ont été utilisées pour capturer l'évolution temporelle des caractéristiques extraites à partir des différentes électrodes. Elles permettent ainsi de modéliser la dynamique des signaux cérébraux et d'améliorer la classification dans certaines tâches d'analyse des états cognitifs ou émotionnels.

Malgré ces avantages, les architectures récurrentes présentent également certaines limites, notamment en termes de parallélisation et d'efficacité computationnelle. Ces contraintes ont conduit à l'émergence d'architectures plus récentes basées sur les mécanismes d'attention, telles que les modèles Transformer, qui permettent de modéliser plus efficacement les dépendances globales dans les données séquentielles.

2.3.3 TRANSFORMERS ET MODÉLISATION TEMPORELLE

Les architectures Transformer représentent une évolution majeure dans le domaine de l'apprentissage profond pour l'analyse de données séquentielles. Introduits initialement dans le traitement automatique du langage naturel, ces modèles reposent principalement sur des mécanismes d'attention permettant de modéliser efficacement les dépendances entre différents éléments d'une séquence.

Contrairement aux architectures récurrentes, les Transformers ne traitent pas les données de manière strictement séquentielle. Ils utilisent des mécanismes d'attention permettant d'évaluer directement les relations entre différentes positions dans la séquence. Cette approche facilite la capture de dépendances globales et permet également une meilleure parallélisation lors de l'entraînement.

Dans le contexte des signaux EEG, les architectures basées sur les Transformers ont récemment suscité un intérêt croissant. En effet, ces modèles permettent de capturer des interactions complexes entre différentes électrodes ainsi que les dynamiques temporelles du signal cérébral. Cette capacité à modéliser simultanément les relations spatiales et temporelles constitue un avantage important pour l'analyse des signaux EEG.

Plusieurs travaux récents ont exploré l'utilisation de Transformers pour l'analyse de l'activité cérébrale. Par exemple, Ding et al. ont proposé une approche basée sur des représenta-

tions spatio-temporelles de patches EEG afin de décoder des états cognitifs à partir de signaux cérébraux (Ding *et al.*, 2025). Dans le domaine spécifique de la classification EEG, Wan et al. ont introduit EEGFormer, une architecture basée sur Transformer capable d’exploiter les relations spatiales et temporelles entre les canaux EEG pour améliorer la classification de l’activité cérébrale (Wan *et al.*, 2023).

Ces travaux montrent que les architectures Transformer constituent une alternative prometteuse aux modèles convolutionnels et récurrents pour l’analyse des signaux EEG. Leur capacité à modéliser des interactions globales entre différentes régions du cerveau ouvre de nouvelles perspectives pour la reconnaissance des états émotionnels à partir de l’EEG.

2.3.4 MÉCANISMES D’ATTENTION

Les mécanismes d’attention ont récemment gagné en popularité dans les architectures d’apprentissage profond, en particulier dans les modèles de type Transformer. L’idée principale de l’attention consiste à permettre au modèle de pondérer différemment les éléments d’une entrée en fonction de leur importance pour la tâche étudiée. Autrement dit, le modèle apprend à se concentrer sur les parties les plus pertinentes des données tout en accordant moins d’importance aux informations redondantes ou peu informatives.

Dans le cas des signaux EEG, cette propriété est particulièrement intéressante. Les enregistrements EEG comportent généralement un grand nombre d’électrodes, mais toutes ne contribuent pas de manière équivalente à la discrimination des états émotionnels. Certains canaux peuvent contenir des informations plus pertinentes que d’autres selon la tâche étudiée. Les mécanismes d’attention permettent ainsi d’apprendre automatiquement l’importance relative des différentes électrodes au cours de l’entraînement du modèle.

Plusieurs travaux récents ont exploré cette idée dans le domaine des interfaces cerveau-ordinateur et de l'analyse des signaux EEG. Par exemple, Tong et al. ont proposé une méthode de sélection de canaux EEG basée sur un mécanisme d'attention efficace permettant d'identifier automatiquement les électrodes les plus informatives pour la tâche de classification (Tong *et al.*, 2023). Cette approche illustre le potentiel des mécanismes d'attention pour améliorer l'interprétabilité et l'efficacité des modèles appliqués aux signaux cérébraux.

Dans le contexte de la reconnaissance des émotions, l'intégration de mécanismes d'attention permet non seulement d'améliorer la capacité du modèle à capturer des relations complexes entre les électrodes, mais aussi de mieux comprendre quelles régions cérébrales contribuent le plus à la classification. Cette propriété est particulièrement pertinente pour les approches visant à réduire le nombre d'électrodes tout en conservant des performances élevées.

Ces avancées ont conduit au développement d'architectures combinant Transformers et mécanismes d'attention pour l'analyse des signaux EEG. Parmi celles-ci, le modèle EEGFormer exploite explicitement ces mécanismes afin de modéliser les interactions spatiales et temporelles entre les canaux EEG et d'apprendre l'importance relative des différentes électrodes (Wan *et al.*, 2023).

2.4 SÉLECTION DE VARIABLES ET RÉDUCTION DE CANAUX EEG

Dans les systèmes de reconnaissance des émotions basés sur l'EEG, le nombre d'électrodes utilisées peut être relativement élevé. Certains jeux de données, comme le dataset SEED, comportent par exemple plus de soixante canaux enregistrant simultanément l'activité cérébrale. Bien que cette densité d'électrodes permette de capturer une information spatiale

riche, elle introduit également plusieurs contraintes pratiques. L'installation du dispositif devient plus longue, le système plus coûteux et le traitement des données plus complexe.

Par ailleurs, toutes les électrodes ne contribuent pas de manière équivalente à la tâche de classification. Certaines positions captent des informations particulièrement pertinentes pour la reconnaissance des émotions, tandis que d'autres peuvent être redondantes ou peu informatives. Dans ce contexte, la sélection de variables — ou sélection de canaux EEG — vise à identifier un sous-ensemble d'électrodes capable de conserver l'essentiel de l'information utile tout en réduisant la complexité du système.

La réduction du nombre de canaux présente plusieurs avantages. Elle permet notamment de diminuer la dimension des données d'entrée, de réduire les coûts matériels et de faciliter l'utilisation de dispositifs EEG dans des contextes réels, notamment pour les applications portables ou les systèmes d'interaction homme-machine.

Dans la littérature, les méthodes de sélection de variables sont généralement regroupées en trois grandes catégories : les méthodes de filtrage, les méthodes d'encapsulation et les approches basées sur l'apprentissage. Chacune de ces familles propose une stratégie différente pour identifier les caractéristiques ou les électrodes les plus informatives. La Figure 2.3 illustre ces principales catégories de méthodes de sélection de variables.




FIGURE 2.3 : Principales catégories de méthodes de sélection de variables appliquées aux signaux EEG

Les méthodes de filtrage évaluent l'importance des variables à partir de critères statistiques indépendants du modèle d'apprentissage. Les méthodes d'encapsulation, quant à elles, utilisent directement la performance d'un classifieur pour guider la sélection des variables. Enfin, les approches basées sur l'apprentissage intègrent le mécanisme de sélection directement dans le modèle, notamment dans certaines architectures d'apprentissage profond.

La compréhension de ces différentes approches est essentielle pour analyser les stratégies de réduction d'électrodes dans les systèmes EEG et pour situer les contributions proposées dans la littérature.

2.4.1 MÉTHODES DE FILTRAGE

Les méthodes de filtrage constituent l'une des approches les plus utilisées pour la sélection de variables dans les problèmes d'apprentissage automatique. Leur principe repose sur l'évaluation individuelle de l'importance des caractéristiques à partir de critères statistiques, indépendamment du modèle de classification utilisé par la suite.

Dans le contexte des signaux EEG, ces méthodes permettent d'identifier les électrodes ou les caractéristiques les plus pertinentes en analysant la relation entre les variables d'entrée et

les classes cibles. L'objectif est de sélectionner un sous-ensemble de variables présentant une forte capacité discriminante tout en limitant la redondance entre les caractéristiques retenues.

Parmi les méthodes de filtrage les plus couramment utilisées dans la littérature figurent notamment *Minimum Redundancy Maximum Relevance* (mRMR) et *ReliefF*. La méthode mRMR vise à sélectionner des variables fortement corrélées avec la variable cible tout en minimisant la redondance entre les caractéristiques sélectionnées. Cette stratégie permet d'obtenir un ensemble de variables à la fois pertinent et compact.

La méthode ReliefF adopte une approche différente en estimant l'importance de chaque variable à partir de sa capacité à distinguer des instances appartenant à différentes classes. Elle évalue les différences entre les voisins proches d'un échantillon dans l'espace des caractéristiques afin d'identifier les variables contribuant le plus à la discrimination des classes.

Ces méthodes présentent plusieurs avantages, notamment une faible complexité computationnelle et une indépendance vis-à-vis du modèle d'apprentissage. Elles sont donc particulièrement adaptées aux problèmes impliquant un grand nombre de variables, comme c'est souvent le cas dans l'analyse des signaux EEG ([Zhang et al., 2016](#)).

2.4.2 MÉTHODES D'ENCAPSULATION

Contrairement aux méthodes de filtrage, les méthodes d'*encapsulation* (wrapper) évaluent directement l'utilité des variables en fonction des performances obtenues par un modèle de classification. L'idée consiste à rechercher un sous-ensemble de variables capable d'optimiser les performances du classifieur utilisé. Ainsi, la sélection des variables dépend directement du modèle d'apprentissage choisi.

Le principe général des méthodes d'encapsulation repose sur une stratégie de recherche dans l'espace des variables possibles. À chaque étape, différents sous-ensembles de variables sont évalués en entraînant un modèle de classification et en mesurant ses performances. Les variables qui permettent d'obtenir les meilleurs résultats sont alors retenues.

Plusieurs stratégies de recherche sont couramment utilisées dans cette famille de méthodes. Parmi les plus connues figurent *Sequential Forward Selection* (SFS), *Sequential Backward Selection* (SBS) et *Sequential Backward Floating Selection* (SBFS). La méthode SFS construit progressivement un sous-ensemble de variables en ajoutant à chaque étape la variable qui améliore le plus la performance du modèle. À l'inverse, la méthode SBS commence avec l'ensemble complet des variables et supprime progressivement celles qui contribuent le moins à la performance.

La méthode SBFS constitue une extension plus flexible de ces approches. Elle permet d'ajouter ou de retirer dynamiquement des variables au cours du processus de sélection afin d'explorer plus efficacement l'espace des combinaisons possibles.

Dans le contexte des signaux EEG, les méthodes d'encapsulation sont souvent utilisées pour identifier des sous-ensembles optimaux d'électrodes permettant d'améliorer les performances de classification tout en réduisant la dimension des données d'entrée. Cependant, ces méthodes présentent généralement un coût computationnel plus élevé que les méthodes de filtrage, car elles nécessitent l'entraînement répété d'un modèle de classification pour évaluer chaque combinaison de variables.

2.4.3 MÉTHODES BASÉES SUR L'APPRENTISSAGE

Les méthodes basées sur l'apprentissage constituent une approche plus récente pour la sélection de variables. Contrairement aux méthodes de filtrage et d'encapsulation, ces

approches intègrent directement le processus de sélection au sein du modèle d'apprentissage lui-même. Autrement dit, l'importance des variables est apprise automatiquement pendant l'entraînement du modèle.

Dans le domaine des signaux EEG, l'essor des techniques d'apprentissage profond a permis de développer des modèles capables d'extraire automatiquement des représentations pertinentes à partir de données multicanaux. Les architectures profondes peuvent ainsi apprendre des relations complexes entre les différentes régions du cerveau sans nécessiter une ingénierie manuelle des caractéristiques.

Plusieurs travaux ont montré que certains mécanismes intégrés aux architectures d'apprentissage profond permettent d'identifier implicitement l'importance relative des canaux EEG. Parmi ces mécanismes, les techniques basées sur l'attention permettent d'attribuer des poids différents aux électrodes en fonction de leur contribution à la tâche de classification. Ces approches offrent ainsi une forme de sélection adaptative des canaux directement intégrée dans le modèle ([Tong et al., 2023](#); [Wan et al., 2023](#)).

Dans ce contexte, les méthodes basées sur l'apprentissage offrent une alternative intéressante aux approches classiques de sélection de variables. En apprenant directement l'importance des caractéristiques à partir des données, elles permettent de mieux capturer les interactions complexes entre les différents canaux EEG. Toutefois, ces approches nécessitent généralement une quantité plus importante de données et des ressources computationnelles plus élevées que les méthodes traditionnelles.

2.4.4 LIMITES THÉORIQUES DES APPROCHES EXISTANTES

Malgré les progrès réalisés dans les méthodes de sélection de variables appliquées aux signaux EEG, plusieurs limites subsistent dans les approches existantes. Les méthodes de

filtrage, bien qu’efficaces et peu coûteuses en calcul, évaluent généralement les variables de manière indépendante du modèle de classification. Cette indépendance peut limiter leur capacité à capturer les interactions complexes entre différentes électrodes, qui jouent pourtant un rôle important dans l’analyse des signaux cérébraux.

Les méthodes d’encapsulation permettent quant à elles d’intégrer directement les performances du classifieur dans le processus de sélection. Cependant, ces approches nécessitent l’entraînement répété du modèle pour évaluer différentes combinaisons de variables, ce qui entraîne souvent un coût computationnel élevé, particulièrement lorsque le nombre de canaux EEG est important.

Les approches basées sur l’apprentissage, notamment celles utilisant des architectures d’apprentissage profond, offrent une alternative plus flexible en permettant au modèle d’apprendre automatiquement l’importance relative des variables. Toutefois, ces méthodes reposent souvent sur des configurations EEG denses et ne visent pas toujours explicitement la réduction du nombre d’électrodes.

Ainsi, malgré les nombreuses approches proposées dans la littérature, le compromis entre réduction du nombre de canaux EEG, maintien des performances de classification et efficacité computationnelle demeure un défi important. Cette problématique souligne l’intérêt d’explorer des architectures capables d’apprendre des représentations spatiales pertinentes tout en permettant une réduction progressive du nombre d’électrodes.

2.5 MÉTRIQUES D’ÉVALUATION EN CLASSIFICATION

L’évaluation des performances d’un modèle de classification constitue une étape essentielle dans l’analyse des systèmes d’apprentissage automatique. Dans le contexte de la

reconnaissance des émotions basée sur l’EEG, différentes métriques sont utilisées afin de mesurer la capacité du modèle à distinguer correctement les différentes classes émotionnelles.

Ces métriques permettent d’évaluer la qualité des prédictions du modèle à partir de la comparaison entre les classes réelles et les classes prédites. Les mesures les plus couramment utilisées incluent l’exactitude, la précision, le rappel et le score F1. Dans certains cas, l’analyse peut également être complétée par la courbe ROC et l’aire sous la courbe (ROC-AUC).

Ces indicateurs fournissent une vision complémentaire des performances du modèle et permettent d’obtenir une évaluation plus complète du comportement du classifieur.

2.5.1 EXACTITUDE, PRÉCISION, RAPPEL ET SCORE F1

Les métriques de classification reposent généralement sur la matrice de confusion, qui compare les classes prédites par le modèle aux classes réelles présentes dans les données.

L’exactitude représente la proportion totale de prédictions correctes réalisées par le modèle. Elle est définie comme le rapport entre le nombre de prédictions correctes et le nombre total d’échantillons :

$$Exactitude = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.1)$$

où TP (vrai positif) correspond au nombre de prédictions positives correctes, TN (vrai négatif) au nombre de prédictions négatives correctes, FP (faux positif) aux fausses prédictions positives et FN (faux négatif) aux fausses prédictions négatives.

La précision mesure la proportion de prédictions positives correctes parmi l’ensemble des prédictions positives :

$$Precision = \frac{TP}{TP + FP} \quad (2.2)$$

Le rappel mesure la capacité du modèle à identifier correctement les échantillons appartenant à la classe positive :

$$Rappel = \frac{TP}{TP + FN} \quad (2.3)$$

Enfin, le score F1 constitue une moyenne harmonique entre la précision et le rappel, permettant de combiner ces deux mesures en une seule métrique :

$$F1 = 2 \times \frac{Precision \times Rappel}{Precision + Rappel} \quad (2.4)$$

Ces métriques sont particulièrement utiles lorsque les classes sont déséquilibrées ou lorsque l'on souhaite analyser plus finement les performances du modèle sur certaines classes spécifiques.

2.5.2 ROC-AUC

La courbe ROC (*Receiver Operating Characteristic*) est une autre méthode couramment utilisée pour évaluer les performances d'un classifieur. Elle représente la relation entre le taux de vrais positifs (*True Positive Rate*) et le taux de faux positifs (*False Positive Rate*) pour différents seuils de décision.

L'aire sous la courbe ROC, appelée ROC-AUC (*Area Under the Curve*), fournit une mesure globale de la capacité du modèle à distinguer les différentes classes. Une valeur de

ROC-AUC proche de 1 indique une excellente capacité de discrimination, tandis qu'une valeur proche de 0.5 correspond à un modèle dont les performances sont similaires à un choix aléatoire.

Dans le cadre de l'évaluation des modèles de reconnaissance des émotions basés sur l'EEG, ces métriques permettent d'analyser de manière détaillée la qualité des prédictions du modèle et de comparer différentes configurations expérimentales.

2.5.3 MATTHEWS CORRELATION COEFFICIENT (MCC)

Le Matthews Correlation Coefficient (MCC) est une métrique d'évaluation souvent utilisée pour mesurer la qualité globale d'un classifieur. Contrairement à l'exactitude, qui peut être influencée par un déséquilibre entre les classes, le MCC prend en compte l'ensemble des éléments de la matrice de confusion et fournit une mesure plus équilibrée des performances du modèle.

Le MCC est défini par l'équation suivante :

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (2.5)$$

où TP représente les vrais positifs, TN les vrais négatifs, FP les faux positifs et FN les faux négatifs.

La valeur du MCC varie entre -1 et 1 . Une valeur proche de 1 indique une excellente performance du modèle, une valeur proche de 0 correspond à une performance équivalente à un choix aléatoire, tandis qu'une valeur négative indique une mauvaise classification.

Dans les systèmes de reconnaissance des émotions basés sur l'EEG, le MCC constitue un indicateur complémentaire permettant d'obtenir une évaluation plus robuste des performances du modèle, notamment lorsque plusieurs classes sont considérées.

Ce chapitre a permis de présenter les principaux fondements théoriques nécessaires à la compréhension de ce travail. Les bases de l'électroencéphalographie, les modèles de représentation des émotions ainsi que les approches d'apprentissage profond appliquées aux signaux EEG ont été introduits. Les différentes méthodes de sélection de variables et les métriques d'évaluation utilisées en classification ont également été présentées.

Ces éléments constituent une base essentielle pour la suite du mémoire. Le chapitre suivant propose une revue des travaux existants afin de situer ce travail par rapport aux approches actuelles et d'identifier les limites auxquelles il cherche à répondre.

CHAPITRE III

REVUE DES TRAVAUX CONNEXES

La reconnaissance automatique des émotions à partir des signaux électroencéphalographiques (EEG) a suscité un intérêt croissant au cours des dernières années. Grâce à sa haute résolution temporelle et à son caractère non invasif, l'EEG constitue une modalité particulièrement pertinente pour l'analyse des processus affectifs. De nombreux travaux ont ainsi exploré son utilisation dans les systèmes d'interaction homme-machine et les interfaces cerveau-ordinateur afin d'identifier différents états émotionnels.

La littérature scientifique propose aujourd'hui une grande diversité d'approches pour traiter et analyser les signaux EEG dans les tâches de reconnaissance des émotions. Ces travaux se distinguent notamment par les techniques d'extraction de caractéristiques utilisées, les modèles d'apprentissage mobilisés, ainsi que les stratégies de sélection ou de réduction des électrodes. Plus récemment, l'émergence de l'apprentissage profond et des mécanismes d'attention a ouvert de nouvelles perspectives pour améliorer à la fois la performance et l'interprétabilité des modèles.

Ce chapitre présente une analyse des travaux existants liés à la reconnaissance des émotions basée sur l'EEG. Les principales approches proposées dans la littérature sont examinées, en particulier celles portant sur la classification des émotions, la réduction du nombre d'électrodes, les méthodes basées sur l'attention ainsi que les études évaluant plusieurs configurations de canaux. Une synthèse comparative est ensuite proposée afin d'identifier les limites des approches actuelles et de mettre en évidence le manque scientifique auquel ce mémoire cherche à répondre.

3.1 RECONNAISSANCE DES ÉMOTIONS À PARTIR DES SIGNAUX EEG

La reconnaissance des émotions à partir des signaux électroencéphalographiques (EEG) constitue aujourd'hui un domaine de recherche actif dans le champ de l'informatique affective et des interfaces cerveau-ordinateur. Grâce à sa capacité à mesurer directement l'activité neuronale avec une haute résolution temporelle, l'EEG permet d'analyser les dynamiques cérébrales associées aux états émotionnels et cognitifs. Contrairement aux signaux physiologiques périphériques, les signaux EEG offrent un accès direct aux processus cérébraux impliqués dans la perception et la régulation des émotions, ce qui explique leur utilisation croissante dans les systèmes de reconnaissance des émotions ([Zheng & Lu, 2015](#); [Qu *et al.*, 2024](#)).

Les premières approches de reconnaissance des émotions basées sur l'EEG reposaient principalement sur l'extraction manuelle de caractéristiques dans différents domaines du signal, notamment le domaine temporel, fréquentiel ou temps-fréquence. Ces caractéristiques étaient ensuite utilisées avec des classificateurs traditionnels tels que les machines à vecteurs de support ou les réseaux de neurones classiques. Par exemple, [Zheng & Lu \(2015\)](#) ont étudié l'influence des bandes de fréquence et des canaux EEG dans la reconnaissance des émotions en utilisant le dataset SEED, montrant que certaines régions cérébrales contribuent davantage à la discrimination des états émotionnels.

Avec l'augmentation de la disponibilité des jeux de données EEG et de la puissance de calcul, des approches plus avancées ont été proposées afin d'améliorer la performance des systèmes de reconnaissance des émotions. Par exemple, [Qu *et al.* \(2024\)](#) ont proposé un cadre hybride combinant différentes représentations de caractéristiques et une stratégie de sélection de canaux critiques afin d'identifier les électrodes les plus informatives pour la reconnaissance des émotions. Les résultats obtenus sur le dataset SEED montrent qu'une sélection appropriée

de canaux peut maintenir une performance élevée tout en réduisant le nombre d'électrodes utilisées.

Dans la même perspective, [Vafaei et al. \(2024\)](#) ont exploré l'utilisation d'autoencodeurs empilés afin d'extraire automatiquement des représentations pertinentes à partir de caractéristiques EEG multi-domaines. Leur étude montre qu'il est possible de réduire le nombre d'électrodes tout en conservant une performance de classification acceptable, notamment en utilisant environ douze canaux EEG pour la classification des états émotionnels.

Malgré ces avancées, plusieurs défis demeurent dans la reconnaissance des émotions basée sur l'EEG. Les signaux EEG sont fortement bruités, présentent une variabilité intersujets importante et impliquent souvent un grand nombre de canaux, ce qui augmente la dimensionnalité des données et la complexité des modèles. Dans ce contexte, la réduction du nombre d'électrodes apparaît comme une problématique centrale afin de développer des systèmes plus efficaces, plus rapides et plus faciles à déployer dans des applications réelles. Ces enjeux ont motivé de nombreux travaux visant à identifier les électrodes les plus informatives et à concevoir des stratégies de sélection ou de réduction de canaux adaptées aux signaux EEG.

3.2 MÉTHODES TRADITIONNELLES DE RÉDUCTION ET DE SÉLECTION DES CANAUX EEG

La forte dimensionnalité des signaux EEG constitue l'un des principaux défis dans les systèmes de reconnaissance des émotions. Les configurations d'acquisition modernes utilisent souvent un grand nombre d'électrodes afin de capturer une information spatiale riche de l'activité cérébrale. Toutefois, l'utilisation d'un nombre élevé de canaux introduit également des problèmes de redondance, de complexité computationnelle et de temps d'installation des

dispositifs. Pour ces raisons, de nombreux travaux ont exploré des stratégies de réduction ou de sélection des électrodes afin d'identifier des sous-ensembles de canaux capables de préserver l'information discriminante tout en simplifiant le système global ([Atyabi et al., 2012](#); [Aljalal et al., 2024](#)).

Plusieurs approches reposent sur des techniques d'optimisation visant à rechercher automatiquement les électrodes les plus informatives. Par exemple, [Atyabi et al. \(2012\)](#) ont proposé une méthode basée sur la sélection évolutionnaire de caractéristiques pour réduire le nombre d'électrodes dans les systèmes de classification EEG. Leur approche modélise la sélection des électrodes comme un problème d'optimisation combinatoire et permet d'identifier des sous-ensembles compacts tout en maintenant une performance de classification compétitive.

D'autres travaux ont exploré des méthodes d'optimisation multi-objectifs afin d'équilibrer simultanément la performance de classification et le nombre d'électrodes utilisées. [Aljalal et al. \(2024\)](#), par exemple, ont proposé une stratégie combinant sélection de canaux et sélection de caractéristiques dans le cadre de la détection du trouble cognitif léger à partir de signaux EEG. Les résultats expérimentaux montrent qu'un sous-ensemble d'environ sept électrodes peut atteindre une précision de classification d'environ 95.28%, illustrant le potentiel des stratégies de réduction pour simplifier les systèmes EEG tout en conservant de bonnes performances.

D'autres études ont également démontré que des réductions importantes du nombre d'électrodes peuvent être réalisées sans perte significative de performance. [Fonseca et al. \(2024\)](#) ont proposé un modèle de réduction d'électrodes pour le diagnostic de troubles du spectre de l'autisme à partir de signaux EEG et de techniques d'apprentissage automatique. Leur étude montre qu'une précision de classification pouvant atteindre 95.44% peut être

obtenue avec seulement dix-sept électrodes, ce qui confirme la possibilité de réduire significativement la configuration des capteurs.

Dans un autre contexte, [Chakraborty et al. \(2021\)](#) ont formulé le problème de sélection d'électrodes comme un jeu de signalisation basé sur une logique floue de type intervalle-2. Les résultats expérimentaux indiquent qu'une configuration très compacte d'environ cinq électrodes peut atteindre une précision de classification proche de 89.06%, démontrant l'efficacité de cette approche pour identifier des canaux particulièrement informatifs.

Par ailleurs, certaines approches ont étudié la réduction d'électrodes dans différents contextes d'application des signaux EEG. Par exemple, [Kheyrkhah & Setarehdan \(2020\)](#) ont analysé l'impact de la réduction d'électrodes dans le diagnostic de la dyslexie et ont montré qu'une précision d'environ 72% pouvait être obtenue avec seulement deux à six électrodes. De même, [Fitriah et al. \(2017\)](#) ont appliqué l'analyse en composantes principales (PCA) afin de réduire le nombre de canaux EEG dans un système de détection d'AVC, atteignant une précision de classification de 100% après réduction de dix-huit à dix électrodes.

Dans l'ensemble, ces travaux montrent que la réduction du nombre d'électrodes constitue une stratégie prometteuse pour simplifier les systèmes EEG tout en conservant des performances de classification élevées. Toutefois, la plupart de ces approches reposent sur des procédures d'optimisation spécifiques ou sur des méthodes de réduction de dimension indépendantes du modèle d'apprentissage utilisé. De plus, les comparaisons entre différentes stratégies de sélection restent souvent limitées ou réalisées dans des conditions expérimentales hétérogènes, ce qui rend difficile l'évaluation systématique de leur efficacité relative.

3.3 MÉTHODES CLASSIQUES DE SÉLECTION DE CANAUX

Plusieurs méthodes de sélection de caractéristiques ont été proposées dans la littérature afin d'identifier les canaux EEG les plus informatifs pour les tâches de classification. Ces approches visent généralement à réduire la redondance entre les signaux tout en conservant les informations les plus discriminantes pour la reconnaissance des états cognitifs ou émotionnels. Parmi les méthodes les plus utilisées, on retrouve notamment les approches basées sur le critère de pertinence statistique, les méthodes de type filtre ainsi que les stratégies de type wrapper. Dans cette section, trois méthodes largement utilisées dans la littérature sont présentées : la méthode de sélection basée sur ReliefF, la méthode Minimum Redundancy Maximum Relevance (mRMR) et la méthode Sequential Backward Floating Selection (SBFS).

3.3.1 MÉTHODE DE SÉLECTION BASÉE SUR RELIEFF

ReliefF est une méthode de sélection de caractéristiques de type filtre largement utilisée dans les problèmes de classification. Le principe de cette approche consiste à estimer l'importance de chaque caractéristique en évaluant sa capacité à distinguer les instances appartenant à des classes différentes tout en restant stable pour les instances de la même classe. Pour cela, l'algorithme compare chaque échantillon avec ses voisins les plus proches appartenant à la même classe et à des classes différentes, puis met à jour un score d'importance pour chaque caractéristique.

Dans le contexte des signaux EEG, ReliefF peut être utilisé pour attribuer un score de pertinence à chaque électrode en fonction de sa contribution à la séparation des classes émotionnelles. Les électrodes ayant les scores les plus élevés sont ensuite sélectionnées afin de former un sous-ensemble de canaux plus compact.

[Zhang et al. \(2016\)](#) ont étudié l'utilisation de ReliefF pour la sélection de capteurs EEG dans les tâches de reconnaissance des émotions. Leurs résultats montrent que l'utilisation de ReliefF permet de réduire significativement le nombre de canaux tout en conservant des performances de classification comparables. Par exemple, leur étude montre qu'un sous-ensemble d'environ huit canaux peut atteindre une précision moyenne d'environ $58.51\% \pm 10.05$, alors que la configuration initiale utilisant dix-neuf canaux atteint une précision d'environ $59.13\% \pm 11.00$. Ces résultats suggèrent qu'une réduction importante du nombre de capteurs peut être réalisée sans perte majeure de performance.

Malgré sa simplicité et sa faible complexité computationnelle, ReliefF présente certaines limites. En particulier, l'évaluation des caractéristiques est réalisée de manière indépendante, ce qui peut conduire à négliger certaines interactions entre les canaux EEG.

3.3.2 MÉTHODE MINIMUM REDUNDANCY MAXIMUM RELEVANCE

La méthode Minimum Redundancy Maximum Relevance (mRMR) est une approche de sélection de caractéristiques basée sur la théorie de l'information. Son objectif est de sélectionner un sous-ensemble de caractéristiques qui maximise la pertinence par rapport aux étiquettes de classe tout en minimisant la redondance entre les caractéristiques sélectionnées.

Dans le cas des signaux EEG, chaque électrode peut être considérée comme une caractéristique candidate. L'algorithme mRMR évalue alors la dépendance statistique entre chaque canal et les classes émotionnelles tout en pénalisant les canaux fortement corrélés entre eux.

[Xu et al. \(2019\)](#) ont appliqué la méthode mRMR dans un système de reconnaissance des émotions basé sur l'EEG. Les résultats obtenus sur le dataset DEAP montrent que la sélection d'un sous-ensemble de canaux permet de maintenir des performances proches de celles obtenues avec l'ensemble complet des électrodes. Plus précisément, l'utilisation de

vingt-huit canaux permet d'atteindre une précision d'environ 80.83%, tandis que la réduction à vingt-deux canaux entraîne une précision d'environ 79.46%. La perte de performance reste donc limitée à environ 1.37%, ce qui démontre l'efficacité de cette méthode pour réduire la dimensionnalité des signaux EEG.

Cependant, mRMR repose sur des mesures statistiques pair-à-pair et ne prend pas en compte des interactions plus complexes entre plusieurs canaux, ce qui peut limiter sa capacité à capturer certaines structures spatiales des signaux EEG.

3.3.3 MÉTHODE SEQUENTIAL BACKWARD FLOATING SELECTION

Sequential Backward Floating Selection (SBFS) est une méthode de sélection de caractéristiques de type wrapper qui évalue directement l'impact des caractéristiques sur les performances d'un classificateur. Contrairement aux méthodes de type filtre, SBFS intègre le modèle de classification dans le processus de sélection.

Le principe de SBFS consiste à partir de l'ensemble complet des caractéristiques puis à supprimer progressivement celles qui contribuent le moins à la performance du classificateur. L'algorithme introduit également des étapes de réintroduction de caractéristiques précédemment supprimées afin d'éviter les décisions irréversibles et d'améliorer la qualité du sous-ensemble final.

[Tang et al. \(2022\)](#) ont appliqué SBFS à la sélection de canaux EEG dans un système de classification d'imagerie motrice. Les résultats expérimentaux montrent que la méthode permet d'améliorer significativement la précision de classification par rapport à l'utilisation de tous les canaux EEG. Par exemple, les auteurs rapportent une précision moyenne d'environ $71.6\% \pm 7.4$, contre $50.2\% \pm 4.8$ lorsque tous les canaux sont utilisés sans sélection.

Malgré ses performances souvent supérieures aux méthodes de type filtre, SBFS présente un coût computationnel plus élevé, car chaque étape de sélection nécessite l'entraînement et l'évaluation d'un classificateur. Cette complexité peut devenir importante lorsque le nombre initial de canaux EEG est élevé.

3.4 APPROCHES BASÉES SUR L'APPRENTISSAGE PROFOND ET LES MÉCANISMES D'ATTENTION

Au cours des dernières années, l'apprentissage profond a profondément transformé les approches de reconnaissance des émotions basées sur l'EEG. Contrairement aux méthodes traditionnelles reposant sur l'extraction manuelle de caractéristiques, les modèles de deep learning permettent d'apprendre automatiquement des représentations discriminantes directement à partir des signaux EEG bruts ou faiblement prétraités.

Plusieurs architectures neuronales ont été explorées dans la littérature, notamment les réseaux de neurones convolutionnels (CNN), les réseaux récurrents (RNN) et leurs variantes hybrides. Ces modèles sont capables de capturer à la fois les dépendances temporelles et les relations spatiales présentes dans les signaux EEG, ce qui leur permet généralement d'obtenir de meilleures performances que les approches classiques basées sur des caractéristiques conçues manuellement.

Par exemple, [Wan *et al.* \(2023\)](#) ont proposé EEGFormer, une architecture basée sur les Transformers pour la classification de l'activité cérébrale à partir de signaux EEG. Ce type d'architecture exploite des mécanismes d'auto-attention afin de modéliser les relations entre différentes parties du signal et d'extraire des représentations hiérarchiques plus expressives.

Dans la même perspective, [Tong *et al.* \(2023\)](#) ont proposé une méthode de sélection de canaux EEG basée sur un mécanisme d'attention efficace (Efficient Channel Attention). Cette

approche permet d'attribuer dynamiquement un poids d'importance à chaque canal EEG afin de mettre en évidence les électrodes les plus pertinentes pour la tâche de classification.

Plus récemment, les architectures de type Transformer ont également été explorées pour modéliser conjointement les dimensions spatiales et temporelles des signaux EEG. Par exemple, [Ding *et al.* \(2025\)](#) ont proposé un modèle exploitant des représentations spatio-temporelles sous forme de patches EEG afin de capturer les relations complexes entre les canaux et les segments temporels.

Malgré ces avancées, la plupart des approches basées sur l'apprentissage profond utilisent encore l'ensemble complet des électrodes EEG lors de l'entraînement et de l'inférence. Dans ce contexte, la réduction explicite du nombre de canaux reste souvent traitée comme une étape indépendante du modèle d'apprentissage. Par conséquent, les interactions entre la sélection d'électrodes et l'apprentissage des représentations neuronales ne sont pas toujours exploitées de manière optimale.

Ces observations suggèrent que l'intégration directe de mécanismes de sélection ou de pondération des canaux au sein des architectures d'apprentissage profond pourrait constituer une stratégie prometteuse pour améliorer à la fois la performance et l'efficacité des systèmes de reconnaissance des émotions basés sur l'EEG.

Afin de synthétiser les principaux travaux présentés dans cette revue de littérature, le Tableau 3.1 résume les approches existantes en mettant en évidence leurs objectifs, les méthodes utilisées, les jeux de données employés ainsi que leurs principales limites.

TABLEAU 3.1 : Synthèse des travaux étudiés sur la réduction ou la sélection d'électrodes EEG

Référence	Objectif	Contribution	Limites
Zheng & Lu (2015)	Analyse des canaux EEG pour la reconnaissance émotionnelle	Analyse des bandes EEG sur SEED, identification des canaux discriminants	Pas de stratégie explicite de réduction d'électrodes
Qu <i>et al.</i> (2024)	Reconnaissance émotionnelle via sélection de canaux	Cadre hybride CNN-GRU + optimisation sur SEED	Méthode complexe, données limitées
Vafaei <i>et al.</i> (2024)	Réduction EEG pour émotions	Extraction multi-domaines + SVM, 32 $\rightarrow$ 12 canaux	Limité à valence/arousal
Atyabi <i>et al.</i> (2012)	Sélection par algorithmes évolutionnaires	GA/PSO + ELM/SVM, 118 $\rightarrow$ $\sim$ 12 électrodes	Testé sur seulement 5 sujets
Tong <i>et al.</i> (2023)	Optimisation multi-objectif pour EEG	NSGA-II + DWT/VMD, 19 $\rightarrow$ 7 électrodes	Échantillon limité (24 sujets)
Aljalal <i>et al.</i> (2024)	Réduction d'électrodes pour diagnostic TSA	RF/SVM, 64 $\rightarrow$ 17 électrodes, précision $\approx$ 95.44%	Base publique unique
Ding <i>et al.</i> (2025)	Sélection optimale d'électrodes EEG	CSP + logique floue type-2 + LDA, réduction à $\approx$ 5 électrodes	Approche difficilement généralisable

Chakraborty et al. (2021)	Réduction EEG pour dyslexie	MI + CCR, 19 → 2–6 électrodes, précision $\approx 72\%$	Population spécifique (enfants)
Feller & Mohamed (2021)	Réduction dimensionnelle EEG	PCA + XGBoost, 18 → 10 électrodes, précision 100%	Base unique, généralisation limitée
Wang et al. (2021)	Sélection de capteurs EEG par filtre	ReliefF, réduction à 8 canaux, précision $\approx 58.51\%$	Interactions entre canaux ignorées
Kheyrkhah & Setarehdan (2020)	Sélection de canaux EEG pour émotions	mRMR-FS/CS + KELM, 32 → 22 canaux, précision $\approx 79.46\%$	Mesures statistiques pair-à-pair
Xu et al. (2019)	Sélection wrapper de canaux EEG	SBFS + classificateur, précision $\approx 71.6\%$	Coût computationnel élevé
Wan et al. (2023)	Classification EEG avec Transformer	EEGFormer pour modélisation spatio-temporelle	Utilise tous les canaux EEG
Zhang et al. (2016)	Sélection de canaux par attention	CNN + Efficient Channel Attention, 22 → 8 canaux	Pas de validation inter-sujets
Tang et al. (2022)	Modélisation spatio-temporelle EEG	Transformer avec patches EEG	Complexité élevée

L'analyse comparative présentée dans le Tableau 3.1 montre que la majorité des travaux existants se concentrent soit sur des méthodes classiques de sélection de caractéristiques, soit sur des approches basées sur l'apprentissage profond utilisant l'ensemble des électrodes

disponibles. Toutefois, les comparaisons systématiques entre ces différentes approches dans un protocole expérimental unifié restent limitées.

Dans l'ensemble, cette revue met en évidence l'intérêt croissant pour la réduction du nombre d'électrodes EEG dans les systèmes de reconnaissance des émotions. Elle montre également que, malgré des avancées importantes, plusieurs limites subsistent, notamment en ce qui concerne l'hétérogénéité des protocoles expérimentaux et le manque de comparaisons unifiées entre approches classiques et approches basées sur l'apprentissage profond.

Ces constats justifient la démarche adoptée dans ce mémoire. Le chapitre suivant présente la méthodologie proposée pour répondre à cette problématique.

CHAPITRE IV

MÉTHODOLOGIE PROPOSÉE

Ce chapitre présente la méthodologie adoptée dans le cadre de cette recherche visant à réduire le nombre d'électrodes nécessaires à la prédiction de la valence à partir des signaux EEG, tout en maintenant un niveau de performance satisfaisant. L'approche proposée repose sur l'utilisation d'un modèle basé sur les Transformers, nommé EEGFormer, capable de capturer les relations spatiales et temporelles présentes dans les signaux EEG. Dans un premier temps, le jeu de données SEED utilisé dans cette étude est décrit, ainsi que sa structure et le protocole expérimental original. Ensuite, les différentes étapes de prétraitement appliquées aux signaux EEG sont présentées, incluant le fenêtrage temporel, la normalisation des données et les mesures prises afin d'éviter les problèmes de fuite de données. Par la suite, l'architecture du modèle EEGFormer est détaillée, en mettant l'accent sur les mécanismes d'attention permettant d'identifier l'importance relative des différents canaux EEG. Enfin, la stratégie proposée pour la réduction du nombre d'électrodes est expliquée, notamment à travers l'extraction et l'analyse des poids d'attention du modèle.

4.1 VUE D'ENSEMBLE DE L'APPROCHE

Cette section présente une vue globale de l'approche proposée pour la prédiction de la valence à partir de signaux EEG, tout en visant une réduction du nombre d'électrodes nécessaires. L'objectif principal est d'identifier un sous-ensemble compact de canaux EEG permettant de maintenir des performances de classification de la valence comparables à celles obtenues avec l'ensemble complet des électrodes.

Les données EEG utilisées dans cette étude proviennent du jeu de données public SEED, largement utilisé dans la littérature pour la reconnaissance des émotions. Ce jeu de données contient des enregistrements EEG obtenus lors du visionnement de vidéos émotionnelles par des participants.

La méthodologie proposée repose sur l'utilisation d'un modèle basé sur les Transformers, nommé EEGFormer, capable de modéliser les dépendances spatiales et temporelles présentes dans les signaux EEG. Contrairement aux approches traditionnelles reposant sur des méthodes de sélection de caractéristiques indépendantes du modèle, l'approche adoptée dans cette étude exploite directement les mécanismes d'attention du réseau afin d'estimer l'importance relative de chaque canal EEG.

Le pipeline expérimental se compose de plusieurs étapes principales. Dans un premier temps, les signaux EEG du jeu de données SEED sont considérés dans leur forme brute. Ces signaux sont ensuite soumis à différentes étapes de prétraitement afin d'améliorer leur qualité et de réduire le bruit présent dans les enregistrements. Cette étape inclut notamment le fenêtrage temporel, l'association des signaux aux étiquettes émotionnelles correspondantes ainsi que la normalisation des données.

Après le prétraitement, des caractéristiques pertinentes sont extraites des signaux EEG afin de représenter les informations discriminantes liées aux états émotionnels. Ces représentations sont ensuite fournies en entrée au modèle EEGFormer. Le modèle apprend à extraire automatiquement des représentations discriminantes en combinant des mécanismes d'attention spatiale et temporelle afin de capturer les relations entre les différents canaux EEG.

Enfin, les sorties du modèle sont utilisées pour effectuer la classification de la valence en différentes catégories. Les poids d'attention générés par le modèle permettent également

d'évaluer l'importance relative des différents canaux EEG, ce qui permet d'identifier les électrodes les plus pertinentes et d'étudier différentes configurations réduites de capteurs.

La Figure 4.1 illustre le pipeline général de l'approche proposée, depuis l'acquisition des signaux EEG du jeu de données SEED jusqu'à la classification de la valence.




FIGURE 4.1 : Pipeline de l'approche proposée pour la prédiction de la valence à partir des signaux EEG.

4.2 DESCRIPTION DU JEU DE DONNÉES SEED

Les données EEG utilisées dans cette étude proviennent du jeu de données public SEED¹, largement utilisé dans la littérature pour la reconnaissance des émotions à partir de signaux EEG.

1. <https://bcmi.sjtu.edu.cn/home/seed/seed.html>

Ce jeu de données contient des enregistrements EEG collectés lors d'expériences où des participants visionnent des vidéos émotionnelles. Les signaux enregistrés sont associés à différentes catégories émotionnelles et constituent une ressource importante pour l'évaluation des modèles d'apprentissage automatique dans ce domaine.

Les sous-sections suivantes présentent la structure du jeu de données, le protocole expérimental utilisé pour la collecte des données ainsi que les raisons ayant motivé le choix de ce jeu de données dans le cadre de ce travail.

4.2.1 STRUCTURE DES DONNÉES

Le jeu de données SEED contient des enregistrements EEG collectés auprès de 15 participants. Chaque participant a participé à trois sessions expérimentales réalisées à des moments différents afin d'assurer une variabilité temporelle dans les enregistrements.

Au cours de chaque session, les participants visionnent 15 extraits vidéo sélectionnés pour induire différents états émotionnels. Ces vidéos ont été choisies de manière à provoquer trois catégories émotionnelles principales : positif, neutre et négatif. Chaque vidéo est associée à une étiquette émotionnelle correspondant à l'état émotionnel qu'elle est censée induire.

L'activité cérébrale des participants est enregistrée à l'aide d'un système EEG comportant 62 électrodes placées selon le système international 10–20. Les signaux EEG sont échantillonnés à une fréquence de 1000 Hz. Les données enregistrées correspondent donc à des séries temporelles multicanales représentant l'activité électrique du cerveau au cours du visionnement des vidéos.

Ainsi, pour chaque participant et pour chaque session, le jeu de données fournit des segments de signaux EEG associés aux étiquettes émotionnelles correspondantes. Cette

organisation des données permet d'utiliser le jeu de données pour entraîner et évaluer des modèles de classification des émotions basés sur les signaux EEG.

4.2.2 JUSTIFICATION DU CHOIX DU JEU DE DONNÉES

Le choix du jeu de données SEED dans cette étude repose sur plusieurs raisons importantes. Tout d'abord, ce jeu de données est largement utilisé dans la littérature scientifique pour les tâches de reconnaissance des émotions basées sur les signaux EEG. Son utilisation dans de nombreux travaux de recherche permet de faciliter la comparaison des performances obtenues avec celles d'autres méthodes proposées dans le domaine.

Ensuite, le jeu de données SEED présente une structure particulièrement adaptée à l'étude de la reconnaissance des émotions. Les signaux EEG ont été enregistrés lors de la visualisation de vidéos émotionnelles soigneusement sélectionnées afin de provoquer différents états émotionnels chez les participants. Cette configuration expérimentale permet d'obtenir des données EEG associées à des catégories émotionnelles clairement définies.

De plus, l'utilisation d'un système d'acquisition comportant 62 électrodes permet de disposer d'une information spatiale riche sur l'activité cérébrale. Cette caractéristique est particulièrement pertinente dans le cadre de ce travail, dont l'objectif est d'étudier l'impact de la réduction du nombre d'électrodes sur les performances de classification des émotions.

Enfin, la disponibilité publique du jeu de données et sa large utilisation dans la communauté scientifique en font une ressource fiable pour l'évaluation des modèles d'apprentissage automatique appliqués aux signaux EEG. Pour ces différentes raisons, le jeu de données SEED constitue un choix pertinent pour l'évaluation du modèle utilisé dans ce mémoire.

4.3 PRÉTRAITEMENT DES SIGNAUX EEG

Avant l'entraînement du modèle, plusieurs étapes de prétraitement ont été appliquées aux signaux EEG afin de préparer les données pour l'apprentissage automatique. Ces étapes permettent d'améliorer la qualité des données, de réduire l'influence du bruit et de garantir une utilisation correcte des informations lors de l'entraînement et de l'évaluation du modèle.

Le processus de prétraitement comprend notamment le fenêtrage temporel des signaux EEG, l'association des segments aux étiquettes émotionnelles correspondantes, la normalisation robuste des données ainsi que la mise en place de mécanismes visant à éviter le phénomène de *data leakage*. Enfin, une stratégie de validation croisée stratifiée est utilisée afin d'obtenir une estimation fiable et robuste des performances du modèle.

4.3.1 FENÊTRAGE TEMPOREL

Les signaux EEG sont des séries temporelles continues qui doivent être segmentées afin d'être exploitées par les modèles d'apprentissage automatique. Dans ce travail, les signaux ont été divisés en segments temporels de longueur fixe à l'aide d'une technique de fenêtrage.

Le fenêtrage temporel consiste à découper les signaux EEG en plusieurs sous-segments consécutifs appelés fenêtres. Chaque fenêtre contient un ensemble de mesures EEG enregistrées simultanément sur l'ensemble des électrodes pendant une durée donnée. Cette approche permet d'augmenter le nombre d'échantillons disponibles pour l'apprentissage et de capturer les variations temporelles des signaux EEG associées aux états émotionnels.

Après cette étape, chaque segment EEG est représenté sous la forme d'un tenseur tridimensionnel de dimension $[N, C, T]$, où N correspond au nombre de segments, C au

nombre de canaux EEG (électrodes) et T au nombre d'échantillons temporels dans chaque fenêtre. Cette représentation constitue l'entrée principale du modèle considéré dans ce travail.

4.3.2 CORRESPONDANCE SIGNAUX-LABELS

Après le fenêtrage temporel, chaque segment EEG est associé au label émotionnel correspondant afin de permettre l'apprentissage supervisé du modèle. Dans le jeu de données SEED, les signaux sont enregistrés lors du visionnement de vidéos émotionnelles, chacune étant associée à une catégorie émotionnelle (positive, neutre ou négative).

Ainsi, chaque segment extrait hérite du label de la séquence à laquelle il appartient. Les données sont alors organisées sous la forme de deux ensembles complémentaires : une matrice contenant les segments EEG et un vecteur contenant les labels associés.

Plus précisément, les données sont représentées sous la forme d'un tenseur $X \in \mathbb{R}^{N \times C \times T}$, où N correspond au nombre de segments, C au nombre d'électrodes et T à la longueur temporelle de chaque segment, ainsi que d'un vecteur y contenant les étiquettes émotionnelles correspondantes.

Cette organisation permet d'assurer une correspondance directe entre chaque segment EEG et son label, condition essentielle pour l'entraînement et l'évaluation du modèle de classification.

4.3.3 NORMALISATION ROBUSTE

Les signaux EEG peuvent présenter des variations importantes d'amplitude entre les différents enregistrements ainsi qu'entre les électrodes. Afin d'améliorer la stabilité de l'ap-

prentissage du modèle et de limiter l'influence des valeurs extrêmes, une étape de normalisation est appliquée aux segments EEG.

Dans ce travail, une normalisation robuste basée sur la médiane et l'intervalle interquartile (*Interquartile Range*, IQR) est utilisée. Contrairement à la normalisation classique reposant sur la moyenne et l'écart-type, cette approche est moins sensible aux valeurs aberrantes et aux artefacts fréquemment présents dans les signaux EEG.

Concrètement, pour chaque canal EEG, la médiane et l'IQR sont estimés à partir de l'ensemble d'entraînement. Les signaux sont ensuite normalisés en soustrayant la médiane et en divisant par l'IQR correspondant. Afin d'éviter toute instabilité numérique, une borne minimale est appliquée à l'IQR lorsque celui-ci prend des valeurs très faibles.

Cette procédure permet d'homogénéiser l'échelle des différents canaux EEG et contribue à améliorer la robustesse du modèle lors de l'apprentissage.

4.3.4 PRÉVENTION DES FUITES DE DONNÉES

Lors de l'entraînement d'un modèle d'apprentissage automatique, il est essentiel d'éviter toute fuite d'information entre les ensembles de données utilisés pour l'apprentissage et ceux utilisés pour l'évaluation. Ce phénomène, appelé fuite de données, peut conduire à une surestimation artificielle des performances du modèle.

Afin d'éviter ce problème, les données ont d'abord été divisées en deux ensembles distincts : un ensemble d'apprentissage et un ensemble de test indépendant. L'ensemble de test est conservé exclusivement pour l'évaluation finale du modèle et n'est jamais utilisé durant l'entraînement.

La séparation des données a été réalisée au niveau des segments EEG à l'aide d'un échantillonnage stratifié, sans regroupement explicite selon l'identité des participants. Par conséquent, des segments issus d'un même participant peuvent être répartis entre les ensembles d'apprentissage et de test. L'ensemble de test demeure toutefois indépendant au niveau des segments, ceux-ci n'étant jamais utilisés durant l'entraînement.

De plus, les statistiques utilisées pour la normalisation des données (médiane et intervalle interquartile) sont calculées uniquement à partir des données d'apprentissage. Ces mêmes paramètres sont ensuite appliqués de manière cohérente à l'ensemble des données utilisées dans la validation croisée ainsi qu'à l'ensemble de test indépendant. Cette stratégie garantit que le modèle n'utilise aucune information provenant des données d'évaluation durant la phase d'apprentissage.

4.3.5 VALIDATION CROISÉE (STRATIFIED K-FOLD)

Afin d'obtenir une estimation robuste des performances du modèle, une validation croisée stratifiée (*Stratified K-Fold*) a été utilisée sur l'ensemble d'apprentissage. Cette méthode consiste à diviser les données en K sous-ensembles de taille similaire tout en préservant la distribution des classes dans chaque sous-ensemble.

Lors de chaque itération, un sous-ensemble est utilisé comme ensemble de validation tandis que les $K - 1$ autres sous-ensembles servent à entraîner le modèle. Ce processus est répété K fois, de sorte que chaque sous-ensemble est utilisé une fois comme ensemble de validation.

Dans ce travail, une validation croisée à $K = 10$ plis a été utilisée. Les performances finales du modèle sont obtenues en calculant la moyenne des métriques de classification sur l'ensemble des plis.

L'utilisation de la validation croisée stratifiée permet de réduire la variance de l'évaluation et d'obtenir une estimation plus fiable des performances du modèle, en particulier dans les problèmes de classification où les classes doivent rester équilibrées dans les ensembles d'apprentissage et de validation.

4.4 ARCHITECTURE DU MODÈLE EEGFORMER

Le modèle utilisé dans ce travail repose sur une architecture inspirée des Transformers afin de capturer les relations spatiales et temporelles présentes dans les signaux EEG. L'objectif principal du modèle est d'extraire automatiquement des représentations discriminantes permettant la classification des états émotionnels à partir des signaux cérébraux.

L'architecture générale du modèle EEGFormer est illustrée à la Figure 4.2.




FIGURE 4.2 : Architecture du modèle EEGFormer.

Cette architecture se compose de plusieurs modules complémentaires permettant d'exploiter les différentes dimensions du signal EEG. Plus précisément, le modèle intègre un module d'attention spatiale permettant d'identifier l'importance relative des électrodes, un encodeur temporel chargé de modéliser l'évolution du signal dans le temps, un mécanisme

d’auto-attention permettant de capturer les dépendances globales, ainsi qu’une tête de classification produisant la prédiction finale.

Les signaux EEG sont fournis au modèle sous la forme d’un tenseur tridimensionnel de dimension $[B, C, T]$, où B représente la taille du lot (*batch size*), C correspond au nombre d’électrodes et T au nombre d’échantillons temporels dans chaque segment EEG. Cette représentation permet de préserver simultanément l’information spatiale liée aux différentes électrodes et la dynamique temporelle des signaux.

Les sous-sections suivantes décrivent plus en détail les différents modules composant l’architecture EEGFormer.

4.4.1 REPRÉSENTATION D’ENTRÉE

Les segments EEG prétraités constituent l’entrée du modèle EEGFormer. Chaque segment correspond à une fenêtre temporelle extraite du signal EEG et contient les mesures enregistrées par l’ensemble des électrodes.

Les données sont représentées sous la forme d’un tenseur tridimensionnel $X \in \mathbb{R}^{B \times C \times T}$, où B correspond à la taille du lot (*batch size*), C au nombre d’électrodes et T au nombre d’échantillons temporels dans chaque segment EEG.

Dans cette représentation, chaque canal correspond à une électrode EEG et la dimension temporelle représente l’évolution du signal au cours du temps. Cette organisation permet au modèle d’exploiter simultanément les relations spatiales entre les électrodes et la dynamique temporelle des signaux EEG.

4.4.2 MODULE D'ATTENTION SPATIALE

Dans les signaux EEG multicanaux, toutes les électrodes ne contribuent pas de manière équivalente à la reconnaissance des états émotionnels. Certaines régions cérébrales contiennent des informations plus discriminantes que d'autres selon la tâche étudiée.

Afin de permettre au modèle d'identifier automatiquement les électrodes les plus informatives, un module d'attention spatiale est introduit dans l'architecture EEGFormer. Ce mécanisme attribue un poids d'importance à chaque canal EEG, permettant ainsi de moduler la contribution de chaque électrode dans la représentation finale du signal.

Plus précisément, un vecteur de poids est appris pour l'ensemble des électrodes à partir des caractéristiques extraites du signal EEG. Ces poids sont ensuite normalisés à l'aide d'une fonction *softmax* afin d'obtenir une distribution d'importance sur les différents canaux.

Les poids d'attention sont appliqués aux signaux EEG afin de produire une représentation pondérée des canaux. Les électrodes considérées comme plus informatives reçoivent ainsi une contribution plus importante dans le processus de classification.

En plus d'améliorer la capacité du modèle à se concentrer sur les régions cérébrales pertinentes, ces poids d'attention peuvent également être exploités pour analyser l'importance relative des électrodes et guider la stratégie de réduction de canaux étudiée dans ce travail.

4.4.3 ENCODEUR TEMPOREL

Après l'application du module d'attention spatiale, les signaux EEG pondérés sont transmis à un encodeur temporel chargé d'extraire les caractéristiques dynamiques du signal. Dans ce travail, cet encodeur repose sur un réseau de convolution 1D (*Convolutional Neural Network*, CNN) permettant de capturer les motifs temporels présents dans les segments EEG.

Les couches convolutionnelles appliquent des filtres le long de la dimension temporelle afin d'identifier des structures locales du signal, telles que des variations ou des patterns caractéristiques associés aux états émotionnels. L'utilisation de plusieurs couches convolutionnelles permet d'extraire progressivement des représentations de plus haut niveau.

Afin d'améliorer la stabilité de l'apprentissage et la robustesse du modèle, des opérations de normalisation et de régularisation sont également intégrées dans l'encodeur temporel. De plus, une opération de sous-échantillonnage temporel (*pooling*) est appliquée afin de réduire la dimension temporelle des représentations tout en conservant l'information essentielle.

Ce module permet ainsi de transformer les signaux EEG bruts en représentations temporelles plus compactes et informatives, qui seront ensuite exploitées par le mécanisme d'auto-attention du modèle.

4.4.4 MÉCANISME D'AUTO-ATTENTION

Après l'extraction des caractéristiques temporelles par l'encodeur convolutionnel, un mécanisme d'auto-attention est appliqué afin de capturer les dépendances globales présentes dans les représentations du signal EEG. Contrairement aux convolutions, qui se concentrent principalement sur des relations locales, l'auto-attention permet au modèle d'établir des interactions entre différentes positions temporelles du signal.

Dans ce travail, un module d'attention multi-têtes léger est utilisé afin d'analyser les relations entre les différentes caractéristiques temporelles extraites par l'encodeur CNN. Ce mécanisme permet au modèle d'accorder une importance différente aux différentes parties du signal EEG lors de la construction de la représentation finale.

L'utilisation de l'auto-attention permet ainsi de modéliser des dépendances temporelles plus complexes et d'améliorer la capacité du modèle à capturer des patterns globaux associés aux états émotionnels.

4.4.5 TÊTE DE CLASSIFICATION

La représentation finale produite par le module d'auto-attention est ensuite transmise à une tête de classification chargée de prédire la classe émotionnelle associée au segment EEG. Dans ce travail, une couche de type perceptron multicouche (*Multi-Layer Perceptron*, MLP) est utilisée pour effectuer la classification.

Les caractéristiques extraites sont d'abord aplaties (*flatten*) afin de former un vecteur de représentation. Ce vecteur est ensuite traité par une ou plusieurs couches entièrement connectées produisant les scores de classification pour les différentes classes émotionnelles.

La sortie finale du modèle correspond à une distribution de probabilités sur les classes émotionnelles, obtenue à l'aide d'une fonction *softmax*.

4.5 STRATÉGIE DE RÉDUCTION D'ÉLECTRODES

Les systèmes EEG utilisés pour la reconnaissance des émotions reposent généralement sur un grand nombre d'électrodes afin de capturer l'activité cérébrale sur différentes régions du cerveau. Cependant, l'utilisation d'un grand nombre de capteurs augmente la complexité des systèmes EEG, le temps d'installation et le coût du matériel.

Dans ce travail, une stratégie de réduction d'électrodes est proposée afin d'identifier un sous-ensemble d'électrodes capables de maintenir de bonnes performances de classification

tout en réduisant la complexité du système. L'objectif est de déterminer quelles électrodes contribuent le plus à la reconnaissance des émotions.

La stratégie proposée repose sur l'exploitation des poids d'attention appris par le modèle EEGFormer. En effet, le module d'attention spatiale permet d'estimer l'importance relative de chaque électrode durant l'apprentissage. Ces poids peuvent ainsi être utilisés pour analyser la contribution de chaque canal EEG et établir un classement des électrodes.

À partir de ce classement, différents sous-ensembles d'électrodes sont construits afin d'évaluer progressivement l'impact de la réduction du nombre de capteurs sur les performances du modèle.

4.5.1 EXTRACTION DES POIDS D'ATTENTION

Le module d'attention spatiale intégré dans l'architecture EEGFormer attribue un poids d'importance à chaque canal EEG. Ces poids sont appris automatiquement durant l'entraînement du modèle et reflètent la contribution relative de chaque électrode à la tâche de classification des états émotionnels.

Après l'entraînement du modèle, ces poids d'attention peuvent être extraits afin d'analyser l'importance relative des différents canaux EEG. Pour cela, les poids sont agrégés sur l'ensemble des segments, ce qui permet d'obtenir une estimation globale de l'importance de chaque électrode.

Plus précisément, une moyenne des poids d'attention est calculée pour chaque canal, puis les électrodes sont classées par ordre décroissant d'importance. Ce classement permet d'identifier les électrodes les plus informatives pour la tâche de classification.

L'analyse de ces poids constitue une étape clé de l'approche proposée, car elle permet à la fois d'interpréter le comportement du modèle et de guider la sélection de sous-ensembles d'électrodes plus compacts.

4.5.2 CLASSEMENT DES ÉLECTRODES

À partir des poids d'attention extraits du modèle, les électrodes peuvent être classées selon leur importance relative pour la tâche de classification. Les électrodes recevant les poids d'attention les plus élevés sont considérées comme les plus informatives pour la prédiction de la valence.

Ce classement permet d'identifier les régions cérébrales contribuant le plus aux performances du modèle. Il constitue également une base pour la construction de sous-ensembles d'électrodes de taille réduite.

Les électrodes sont ainsi triées par ordre décroissant de leur importance, ce qui permet de sélectionner progressivement les électrodes les plus pertinentes.

La Figure 4.3 illustre la distribution des poids d'attention associés aux différentes électrodes EEG. On observe que certaines électrodes reçoivent des poids nettement plus élevés, indiquant une contribution plus importante à la tâche de classification de la valence.




FIGURE 4.3 : Distribution des poids d'attention normalisés pour les 62 électrodes, triées par ordre décroissant d'importance.

4.5.3 CONSTRUCTION DES SOUS-ENSEMBLES ($62 \rightarrow 48 \rightarrow 32 \rightarrow 16 \rightarrow 8 \rightarrow 6 \rightarrow 4$)

Afin d'évaluer l'impact de la réduction du nombre d'électrodes, plusieurs sous-ensembles de canaux EEG sont construits à partir du classement obtenu. Le nombre d'électrodes est progressivement réduit en conservant uniquement les électrodes les plus importantes selon les poids d'attention.

Dans ce travail, plusieurs configurations sont étudiées, allant de la configuration complète contenant 62 électrodes jusqu'à des configurations plus compactes comprenant 48, 32, 16, 8, 6 et 4 électrodes.

Cette stratégie permet d'analyser l'évolution des performances du modèle en fonction du nombre d'électrodes utilisées et d'identifier un compromis entre précision de classification et complexité du système EEG.

4.6 JUSTIFICATION DES CHOIX MÉTHODOLOGIQUES

Les choix méthodologiques adoptés dans ce travail visent à concevoir une approche robuste pour la reconnaissance des émotions à partir des signaux EEG tout en permettant l'analyse de la réduction du nombre d'électrodes.

Tout d'abord, le jeu de données SEED a été sélectionné car il constitue l'un des jeux de données publics les plus largement utilisés pour l'étude de la reconnaissance des émotions à partir des signaux EEG. Il fournit des enregistrements EEG multicanaux de haute qualité associés à des étiquettes émotionnelles clairement définies, ce qui permet une évaluation fiable des modèles de classification.

Ensuite, l'architecture EEGFormer a été retenue en raison de sa capacité à modéliser simultanément les dépendances spatiales et temporelles présentes dans les signaux EEG. Le module d'attention spatiale permet d'identifier l'importance relative des électrodes, tandis que les mécanismes d'encodage temporel et d'auto-attention permettent de capturer la dynamique temporelle des signaux.

La stratégie de réduction d'électrodes proposée dans ce travail repose sur l'exploitation des poids d'attention appris par le modèle. Cette approche permet d'identifier automatiquement les électrodes les plus informatives sans recourir à des méthodes heuristiques externes.

Enfin, afin d'évaluer de manière rigoureuse les performances du modèle et de comparer l'approche proposée avec des méthodes existantes, plusieurs techniques de sélection de caractéristiques classiques ont été considérées, notamment mRMR, ReliefF et SBFS. Ces méthodes servent de référence pour analyser l'efficacité de la stratégie de réduction basée sur l'attention.

Ces choix méthodologiques permettent ainsi d'évaluer de manière complète l'impact de la réduction du nombre d'électrodes sur les performances de classification tout en assurant la robustesse des résultats obtenus.

Disponibilité du code Afin d'assurer la reproductibilité des expériences et de garantir la transparence de la méthodologie proposée, le code source complet de ce travail est mis à disposition en ligne. Le dépôt inclut l'ensemble du pipeline expérimental, comprenant les étapes de prétraitement des données, l'implémentation du modèle EEGFormer, ainsi que les procédures d'entraînement et d'évaluation.

Le code est accessible à l'adresse suivante : <https://github.com/elhadjimbayebiteye/EEG-Emotion-Project>.

Ainsi, ce chapitre a présenté la méthodologie adoptée pour la reconnaissance des émotions à partir des signaux EEG, basée sur le modèle EEGFormer. Les principales étapes du pipeline, du prétraitement des données à la stratégie de réduction d'électrodes fondée sur les mécanismes d'attention, ont été décrites.

Le chapitre suivant est consacré à l'expérimentation et à l'analyse des résultats obtenus, afin d'évaluer les performances du modèle et de comparer l'approche proposée aux méthodes existantes.

CHAPITRE V

EXPÉRIMENTATION ET RÉSULTATS

5.1 PROTOCOLE EXPÉRIMENTAL

Cette section présente le protocole expérimental utilisé pour évaluer les performances du modèle considéré dans ce travail. Elle décrit la stratégie de séparation des données, la procédure de validation croisée ainsi que les paramètres d'entraînement utilisés lors des expériences.

L'objectif est de garantir une évaluation rigoureuse et reproductible du modèle dans le cadre de la reconnaissance des émotions à partir de signaux EEG. Les expériences ont été réalisées sur le jeu de données SEED en utilisant une configuration expérimentale permettant d'assurer une estimation fiable des performances du modèle.

5.1.1 STRATÉGIE DE SÉPARATION DES DONNÉES

Afin d'évaluer de manière rigoureuse les performances du modèle utilisé, une stratégie de séparation des données a été mise en place sur le jeu de données SEED.

Dans un premier temps, l'ensemble des données a été divisé en deux sous-ensembles distincts. 80% des données ont été utilisées pour l'apprentissage du modèle, tandis que les 20% restants ont été réservés comme ensemble de test indépendant. Cet ensemble de test est strictement conservé à part et utilisé uniquement à la fin du processus, après l'application de la validation croisée sur l'ensemble d'apprentissage, afin de garantir une évaluation objective des performances finales.

Afin de conserver une répartition équilibrée des classes émotionnelles dans chaque sous-ensemble, une stratégie d'échantillonnage stratifié (*stratified sampling*) a été appliquée lors de cette division.

5.1.2 VALIDATION CROISÉE

Afin d'obtenir une évaluation plus robuste et fiable des performances du modèle, une validation croisée stratifiée de type *Stratified K-Fold* a été appliquée sur l'ensemble d'apprentissage.

Dans ce cadre, une validation croisée avec $K = 10$ folds a été utilisée. À chaque itération, neuf folds sont employés pour entraîner le modèle, tandis que le fold restant est utilisé pour la validation. Ce processus est répété jusqu'à ce que chaque fold ait été utilisé une fois comme ensemble de validation.

Les performances finales du modèle sont obtenues en calculant la moyenne des métriques sur l'ensemble des folds, ce qui permet de réduire la variabilité liée à la partition des données et d'obtenir une estimation plus stable.

Enfin, l'ensemble de test indépendant est utilisé uniquement à la fin du processus, afin d'évaluer la capacité de généralisation du modèle sur des données totalement inédites.

5.1.3 PARAMÈTRES D'ENTRAÎNEMENT

Les expériences ont été réalisées en utilisant le modèle EEGFormer utilisé dans ce travail. L'entraînement du modèle a été effectué à l'aide de la bibliothèque *PyTorch*, qui permet une implémentation flexible des architectures de réseaux de neurones et une utilisation efficace des ressources de calcul.

Afin d’obtenir les meilleures performances possibles, les hyperparamètres du modèle ont été optimisés à l’aide de la bibliothèque *Optuna*. Optuna est un framework d’optimisation automatique des hyperparamètres qui utilise des stratégies de recherche efficaces pour explorer l’espace des paramètres et identifier les configurations les plus performantes.

Plusieurs essais d’entraînement ont été réalisés afin de déterminer les valeurs optimales des hyperparamètres du modèle. Les paramètres explorés incluent notamment le taux d’apprentissage, la taille du batch, les taux de dropout ainsi que certains paramètres architecturaux du modèle.

Le modèle a été entraîné en utilisant l’optimiseur AdamW, largement utilisé dans les architectures basées sur les Transformers. De plus, une stratégie d’*early stopping* a été appliquée afin d’éviter le surapprentissage. Cette stratégie consiste à arrêter l’entraînement lorsque les performances sur l’ensemble de validation cessent de s’améliorer pendant un certain nombre d’itérations.

Les principaux hyperparamètres retenus pour l’entraînement du modèle sont résumés dans le Tableau 5.1.

TABLEAU 5.1 : Hyperparamètres utilisés pour l’entraînement du modèle EEGFormer

Paramètre	Valeur
Optimiseur	AdamW
Taux d’apprentissage maximal	5.5×10^{-4}
Batch size	128
Nombre maximal d’époques	100
Weight decay	3.5×10^{-4}
Fonction de perte	Focal Loss
Label smoothing	0.035
Dimension d’embedding	288
Dimension cachée du module d’attention	64
Dropout CNN	0.20
Dropout tête de classification / attention	0.18
Nombre de têtes d’attention	6
Patience (early stopping)	10
Div factor (OneCycleLR)	20.0
Graine aléatoire	42

5.2 MÉTHODES DE COMPARAISON

Afin d’évaluer l’efficacité de la méthode proposée pour la sélection d’électrodes EEG, plusieurs méthodes classiques de sélection de caractéristiques ont été utilisées comme approches de référence. Ces méthodes sont largement utilisées dans la littérature pour identifier les canaux EEG les plus informatifs dans les tâches de classification.

Dans ce travail, trois méthodes de sélection d’électrodes ont été considérées : *Minimum Redundancy Maximum Relevance (mRMR)*, *ReliefF* et *Sequential Backward Feature Selection (SBFS)*. Ces approches permettent d’identifier des sous-ensembles d’électrodes pertinents en se basant sur différents critères statistiques ou algorithmiques.

Les électrodes sélectionnées par ces méthodes sont ensuite utilisées pour entraîner le même modèle de classification, afin de comparer les performances obtenues avec celles de la méthode proposée basée sur les poids d'attention du modèle EEGFormer.

5.2.1 MÉTHODE MINIMUM REDUNDANCY MAXIMUM RELEVANCE

La méthode *Minimum Redundancy Maximum Relevance (mRMR)* est une technique de sélection de caractéristiques largement utilisée dans les problèmes de classification. Son objectif est de sélectionner un sous-ensemble de variables qui présentent une forte pertinence vis-à-vis de la variable cible tout en minimisant la redondance entre les caractéristiques sélectionnées.

Dans le contexte des signaux EEG, la méthode mRMR permet d'identifier les électrodes les plus informatives pour la reconnaissance des émotions en maximisant l'information mutuelle entre les canaux EEG et les classes émotionnelles, tout en réduisant la corrélation entre les électrodes sélectionnées.

5.2.2 MÉTHODE BASÉE SUR RELIEFF

ReliefF est une méthode de sélection de caractéristiques basée sur l'évaluation de l'importance des variables en fonction de leur capacité à distinguer les instances appartenant à différentes classes. Cette méthode estime le poids de chaque caractéristique en analysant les différences entre les exemples proches appartenant à la même classe et ceux appartenant à des classes différentes.

Dans le cas des signaux EEG, ReliefF permet d'évaluer l'importance relative de chaque électrode en fonction de sa contribution à la discrimination entre les différentes catégories émotionnelles.

5.2.3 MÉTHODE SEQUENTIAL BACKWARD FLOATING SELECTION

La méthode *Sequential Backward Feature Selection (SBFS)* est une approche itérative de sélection de caractéristiques. Elle commence avec l'ensemble complet des variables, puis supprime progressivement les caractéristiques les moins pertinentes à chaque itération.

À chaque étape, la suppression d'une caractéristique est évaluée en fonction de son impact sur les performances du modèle de classification. Cette procédure est répétée jusqu'à obtenir un sous-ensemble de caractéristiques offrant un bon compromis entre performance et complexité du modèle.

5.3 RÉSULTATS AVEC CONFIGURATION COMPLÈTE (62 ÉLECTRODES)

Dans un premier temps, le modèle EEGFormer utilisé dans ce travail a été entraîné en utilisant l'ensemble complet des 62 électrodes disponibles dans le jeu de données SEED. Cette configuration sert de référence afin d'évaluer l'impact de la réduction progressive du nombre d'électrodes sur les performances du modèle.

L'entraînement du modèle a été réalisé en suivant le protocole expérimental décrit dans la section précédente. Les performances finales ont été évaluées sur un ensemble de test indépendant représentant 20% des données, strictement conservé à part et utilisé uniquement à la fin du processus, après la validation croisée.

Les résultats obtenus avec la configuration complète sont présentés dans le Tableau 5.2. Ces résultats constituent la performance de référence du modèle avant l'application de la stratégie de sélection d'électrodes basée sur les poids d'attention.

TABLEAU 5.2 : Performance du modèle EEGFormer avec la configuration complète (62 électrodes) sur l'ensemble de test (20%)

Métrique	Valeur
Exactitude	84.06%
Précision	83.88%
Rappel	83.91%
Score F1	83.89%
ROC-AUC	0.954
MCC	0.761

5.4 ANALYSE PROGRESSIVE DE LA RÉDUCTION

Afin d'évaluer l'impact de la réduction du nombre d'électrodes sur les performances du modèle utilisé dans ce travail, une analyse progressive a été réalisée en diminuant graduellement le nombre de canaux EEG utilisés.

À partir du modèle initial entraîné avec l'ensemble complet des 62 électrodes, les poids d'attention ont été extraits afin de déterminer l'importance relative de chaque électrode. Les électrodes ont ensuite été classées selon leur contribution au processus de classification. Les sous-ensembles d'électrodes ont été construits en sélectionnant les électrodes les plus importantes selon ce classement.

Plusieurs configurations ont été étudiées, notamment 48, 32, 16, 8, 6 et 4 électrodes. Pour chaque configuration, un nouveau modèle EEGFormer a été entraîné en utilisant uniquement les électrodes sélectionnées. Les performances ont ensuite été évaluées sur l'ensemble de test indépendant représentant 20% du jeu de données.

Les résultats obtenus pour chaque configuration sont présentés dans le Tableau 5.3.

TABEAU 5.3 : Performance du modèle EEGFormer pour différentes configurations d'électrodes sur l'ensemble de test (20%)

Canaux	Exactitude	Précision	Rappel	Score F1	ROC-AUC	MCC
62	84.06%	83.88%	83.91%	83.89%	0.954	0.761
48	83.60%	83.41%	83.45%	83.43%	0.951	0.754
32	84.66%	84.52%	84.51%	84.51%	0.957	0.770
16	84.97%	84.87%	84.85%	84.86%	0.956	0.775
8	83.40%	83.41%	83.20%	83.26%	0.952	0.751
6	80.75%	80.71%	80.56%	80.60%	0.937	0.711
4	79.90%	79.64%	79.69%	79.64%	0.933	0.698

Les résultats montrent que la réduction progressive du nombre d'électrodes n'entraîne pas une dégradation immédiate des performances du modèle.

En particulier, les configurations utilisant 32 et 16 électrodes obtiennent des performances comparables, voire légèrement supérieures, à celles obtenues avec la configuration complète de 62 électrodes. La configuration à 16 électrodes atteint notamment la meilleure performance globale avec une exactitude de 84.97% et un coefficient MCC de 0.775.

Ces observations suggèrent que certaines électrodes présentes dans la configuration complète apportent une information redondante ou peu discriminante pour la tâche de reconnaissance de la valence. La sélection d'un sous-ensemble d'électrodes pertinentes permet ainsi de concentrer l'apprentissage du modèle sur les régions cérébrales les plus informatives.

Lorsque le nombre d'électrodes devient très faible (6 ou 4 électrodes), une baisse plus importante des performances est observée. Cette diminution peut s'expliquer par une perte d'information spatiale nécessaire à la caractérisation complète des états émotionnels.

Globalement, ces résultats démontrent que le modèle EEGFormer est capable de maintenir des performances élevées même avec un nombre réduit d'électrodes, ce qui constitue

un avantage important pour le développement de systèmes EEG plus légers et plus faciles à déployer dans des contextes réels.

Comme illustré à la Figure 5.1, le modèle ne répartit pas son attention de manière uniforme sur l'ensemble des électrodes. Il met plutôt en évidence un sous-ensemble restreint de canaux, suggérant que le mécanisme d'attention permet d'identifier automatiquement les régions spatiales les plus informatives, sans recourir à des contraintes anatomiques explicites.

Sur la base de ce classement des électrodes, une stratégie de réduction progressive a été adoptée. Plusieurs sous-ensembles de taille décroissante (48, 32, 16, 8, 6 et 4 électrodes) ont ainsi été construits en sélectionnant les électrodes les mieux classées.

Il est important de noter que cette sélection est réalisée uniquement après l'entraînement du modèle complet, afin d'éviter toute fuite d'information et de garantir une séparation stricte entre la phase d'apprentissage et la construction des sous-ensembles.

On observe notamment que les électrodes sélectionnées se concentrent majoritairement dans certaines zones de la tête, en particulier au niveau des régions frontales, préfrontales et temporales. Ces observations sont cohérentes avec plusieurs travaux de la littérature montrant que ces régions jouent un rôle important dans le traitement des émotions et dans la reconnaissance de la valence émotionnelle à partir des signaux EEG ([Zheng & Lu, 2015](#); [Mouri *et al.*, 2023](#); [Gkintoni *et al.*, 2025](#)).

Plusieurs études rapportent notamment que les asymétries frontales EEG sont associées aux mécanismes d'approche et d'évitement liés aux émotions positives et négatives. Les travaux de [Mouri *et al.* \(2023\)](#) montrent également que certaines paires d'électrodes frontales et temporales, telles que FT7–FT8 (régions fronto-temporales) et T7–T8 (régions temporales), présentent une contribution importante dans la reconnaissance des états émotionnels. Par

ailleurs, les régions temporelles sont fréquemment associées au traitement émotionnel et à l'intégration des informations affectives (Zheng & Lu, 2015; Gkintoni *et al.*, 2025).

Ainsi, la concentration des électrodes sélectionnées dans ces régions suggère que le modèle EEGFormer est capable d'identifier automatiquement les zones cérébrales les plus discriminantes pour la tâche de reconnaissance des émotions, en cohérence avec les observations rapportées dans la littérature récente.




FIGURE 5.1 : Configurations d'électrodes sélectionnées par le modèle EEGFormer pour différentes tailles de sous-ensembles

5.5 COMPARAISON AVEC LES MÉTHODES CLASSIQUES

Afin d'évaluer l'efficacité de la stratégie de sélection d'électrodes proposée, une comparaison a été réalisée avec plusieurs méthodes classiques de sélection de caractéristiques couramment utilisées dans la littérature. Les méthodes considérées dans cette étude sont mRMR (Minimum Redundancy Maximum Relevance), ReliefF et SBFS (Sequential Backward Floating Selection).

Ces approches sélectionnent les électrodes en se basant principalement sur des critères statistiques ou heuristiques. Par exemple, la méthode mRMR vise à sélectionner des caractéristiques fortement corrélées avec la variable cible tout en minimisant la redondance entre elles. La méthode ReliefF estime l'importance des caractéristiques en évaluant leur capacité à distinguer les instances proches appartenant à différentes classes. Quant à SBFS, il s'agit d'une méthode de sélection séquentielle qui retire progressivement les caractéristiques les moins pertinentes tout en permettant des ajustements dynamiques dans le processus de sélection.

Contrairement à ces approches, la méthode proposée dans ce travail exploite directement les mécanismes d'attention internes du modèle EEGFormer afin d'identifier les électrodes les plus informatives pour la tâche de prédiction de la valence. Les poids d'attention appris durant l'entraînement permettent ainsi d'estimer l'importance relative de chaque électrode de manière intégrée au modèle.

Pour assurer une comparaison équitable, les différentes méthodes ont été utilisées pour sélectionner des sous-ensembles d'électrodes de tailles identiques. Les performances ont ensuite été évaluées en utilisant le même protocole expérimental et le même ensemble de test indépendant représentant 20% du jeu de données.

Lorsque les 62 électrodes sont utilisées, aucune réduction ni sélection de canaux n'est appliquée. Par conséquent, toutes les méthodes exploitent exactement la même configuration EEG complète, ce qui explique l'obtention de performances identiques.

Les performances obtenues pour chaque méthode et chaque configuration d'électrodes sont présentées dans le Tableau 5.4.

TABLEAU 5.4 : Comparaison des performances sur l'ensemble de test selon les méthodes de sélection d'électrodes

Électrodes	Méthode	Exactitude	Précision	Rappel	Score F1	ROC-AUC	MCC
62	Toutes les méthodes	84.06	83.88	83.91	83.89	0.954	0.761
48	Méthode proposée	83.60	83.41	83.45	83.43	0.951	0.754
48	SBFS	81.33	81.32	81.21	81.26	0.940	0.720
48	mRMR	81.33	81.32	81.21	81.26	0.940	0.720
48	ReliefF	83.00	82.93	82.88	82.81	0.951	0.746
32	Méthode proposée	84.66	84.52	84.51	84.51	0.957	0.770
32	SBFS	81.17	81.20	81.08	81.03	0.938	0.719
32	mRMR	81.17	81.20	81.08	81.03	0.938	0.719
32	ReliefF	81.98	81.86	81.85	81.83	0.943	0.730
16	Méthode proposée	84.97	84.87	84.85	84.86	0.956	0.775
16	SBFS	77.37	77.28	77.23	77.25	0.917	0.661
16	mRMR	77.37	77.28	77.23	77.25	0.917	0.661
16	ReliefF	53.15	53.10	52.89	52.57	0.734	0.299
8	Méthode proposée	83.40	83.41	83.20	83.26	0.952	0.751
8	SBFS	68.39	68.47	68.18	68.27	0.857	0.526
8	mRMR	68.39	68.47	68.18	68.27	0.857	0.526
8	ReliefF	56.72	57.11	56.57	56.73	0.768	0.352
6	Méthode proposée	80.75	80.71	80.56	80.60	0.937	0.711
6	SBFS	67.93	68.09	67.75	67.89	0.855	0.519
6	mRMR	67.93	68.09	67.75	67.89	0.855	0.519
6	ReliefF	59.72	60.25	59.66	59.82	0.793	0.397
4	Méthode proposée	79.90	79.64	79.69	79.64	0.933	0.698
4	SBFS	62.07	61.65	61.85	61.59	0.810	0.432
4	mRMR	62.07	61.65	61.85	61.59	0.810	0.432
4	ReliefF	51.23	51.30	51.09	51.12	0.715	0.269

L'analyse des résultats montre que la stratégie de sélection basée sur les poids d'attention du modèle EEGFormer maintient des performances élevées et stables lors de la réduction progressive du nombre d'électrodes. En particulier, les configurations utilisant 32 et 16 électrodes atteignent des performances comparables, voire légèrement supérieures, à celles obtenues avec la configuration complète de 62 électrodes.

Lorsque le nombre d'électrodes diminue davantage (8, 6 et 4 électrodes), une baisse progressive des performances est observée pour l'ensemble des méthodes. Toutefois, la méthode proposée démontre une meilleure robustesse dans ces scénarios de réduction agressive. Les méthodes classiques telles que mRMR et SBFS présentent des tendances de performance similaires mais se dégradent plus rapidement lorsque l'information spatiale devient limitée.

Globalement, ces résultats indiquent que l'apprentissage de l'importance des électrodes directement au sein de l'architecture EEGFormer permet d'identifier des sous-ensembles de canaux plus discriminants et plus stables, tout en conservant de bonnes performances de classification.

5.6 ANALYSE DE ROBUSTESSE SOUS RÉDUCTION AGRESSIVE

Afin d'évaluer la stabilité et la robustesse du modèle utilisé dans ce travail, une validation croisée à 10 folds a été réalisée pour différentes configurations d'électrodes. Cette analyse permet d'estimer la variabilité des performances du modèle lorsque l'entraînement et la validation sont effectués sur différentes partitions du jeu de données.

Dans cette procédure, le jeu d'entraînement est divisé en dix sous-ensembles de taille équivalente. À chaque itération, neuf folds sont utilisés pour l'entraînement du modèle tandis que le fold restant est utilisé pour la validation. Ce processus est répété dix fois de manière à ce que chaque fold soit utilisé une fois comme ensemble de validation. Les performances finales sont ensuite obtenues en calculant la moyenne et l'écart-type des différentes métriques sur l'ensemble des itérations.

Le Tableau 5.5 présente le résumé des performances obtenues pour différentes configurations d'électrodes. Les résultats sont rapportés sous la forme moyenne $\pm$ écart-type pour les métriques d'exactitude, de précision, de rappel, de score F1, de ROC-AUC et de MCC.

Les courbes d'apprentissage et les résultats complémentaires de la validation croisée sont présentés en Annexe A.

TABLEAU 5.5 : Performances du modèle par validation croisée (10 folds) pour différentes configurations d'électrodes

Électrodes	Exactitude	Précision	Rappel	Score F1	ROC-AUC	MCC
62	0.844 $\pm$ 0.018	0.843 $\pm$ 0.018	0.843 $\pm$ 0.018	0.843 $\pm$ 0.018	0.955 $\pm$ 0.009	0.766 $\pm$ 0.027
48	0.840 $\pm$ 0.007	0.839 $\pm$ 0.007	0.839 $\pm$ 0.007	0.839 $\pm$ 0.007	0.953 $\pm$ 0.004	0.761 $\pm$ 0.011
32	0.851 $\pm$ 0.006	0.850 $\pm$ 0.006	0.850 $\pm$ 0.006	0.850 $\pm$ 0.006	0.958 $\pm$ 0.003	0.777 $\pm$ 0.009
16	0.838 $\pm$ 0.005	0.837 $\pm$ 0.005	0.836 $\pm$ 0.005	0.836 $\pm$ 0.005	0.951 $\pm$ 0.003	0.757 $\pm$ 0.008
8	0.839 $\pm$ 0.006	0.838 $\pm$ 0.006	0.838 $\pm$ 0.006	0.838 $\pm$ 0.006	0.953 $\pm$ 0.003	0.759 $\pm$ 0.009
6	0.821 $\pm$ 0.006	0.820 $\pm$ 0.006	0.819 $\pm$ 0.006	0.819 $\pm$ 0.006	0.945 $\pm$ 0.003	0.732 $\pm$ 0.009
4	0.798 $\pm$ 0.006	0.796 $\pm$ 0.006	0.796 $\pm$ 0.006	0.796 $\pm$ 0.006	0.933 $\pm$ 0.002	0.696 $\pm$ 0.009

L'analyse des résultats montre que le modèle EEGFormer conserve des performances relativement stables lorsque le nombre d'électrodes est progressivement réduit. La configuration utilisant 32 électrodes présente même les meilleures performances moyennes, ce qui suggère que certaines électrodes du montage complet peuvent être redondantes pour la tâche de classification de la valence.

Lorsque le nombre d'électrodes est réduit à 16 et 8 canaux, les performances restent proches de celles obtenues avec le montage complet, ce qui confirme la capacité du modèle à extraire des représentations discriminantes même avec un nombre limité de capteurs EEG.

En revanche, lorsque la réduction devient plus agressive (6 et 4 électrodes), une diminution progressive des performances est observée. Malgré cette baisse, les écarts-types restent relativement faibles pour l'ensemble des métriques, ce qui indique une bonne stabilité du modèle entre les différents folds. Ces résultats confirment que l'approche proposée demeure robuste même dans des scénarios de réduction importante du nombre d'électrodes.

5.7 ANALYSE DES POIDS D'ATTENTION ET INTERPRÉTABILITÉ

Au-delà de l'évaluation des performances de classification, il est important de comprendre quelles électrodes contribuent le plus aux prédictions du modèle. L'architecture EEGFormer intègre des mécanismes d'attention permettant d'attribuer un poids à chaque électrode en fonction de son importance relative dans la tâche de prédiction de la valence.

Les poids d'attention appris durant l'entraînement permettent ainsi d'estimer la contribution de chaque canal EEG dans le processus de décision du modèle. À partir de ces poids, les électrodes peuvent être classées selon leur importance relative pour la tâche de classification.

La Figure 4.3, présentée dans la section 4.5.2, illustre le classement des électrodes obtenu à partir des poids d'attention extraits du modèle. Les électrodes associées aux valeurs les plus élevées sont considérées comme les plus informatives pour la prédiction de la valence.

L'analyse de ce classement met en évidence une distribution inégale de l'importance des électrodes. Un nombre limité d'électrodes concentre une grande partie des poids d'attention, tandis que plusieurs autres électrodes présentent des contributions relativement faibles. Cette observation suggère l'existence d'une certaine redondance dans le montage EEG complet.

Ces résultats permettent d'expliquer pourquoi les performances du modèle restent élevées même lorsque le nombre d'électrodes est progressivement réduit. En sélectionnant les électrodes les plus informatives selon leur poids d'attention, il est possible de construire des configurations compactes tout en conservant une capacité de discrimination élevée.

Cette propriété est particulièrement intéressante pour le développement de systèmes EEG plus légers et plus faciles à déployer dans des contextes réels, notamment dans les applications portables ou embarquées où l'utilisation d'un grand nombre d'électrodes peut être contraignante.

5.8 DISCUSSION DES RÉSULTATS

Les résultats obtenus dans ce travail montrent que le modèle EEGFormer est capable de maintenir de bonnes performances de classification de la valence même lorsque le nombre d'électrodes est fortement réduit. Cette observation met en évidence la capacité du modèle à extraire des représentations spatiales discriminantes à partir d'un nombre limité de canaux EEG.

L'analyse progressive de la réduction des électrodes montre qu'une diminution modérée du nombre de capteurs n'entraîne pas nécessairement une dégradation des performances. En particulier, les configurations utilisant 32 et 16 électrodes présentent des performances comparables, voire légèrement supérieures dans certains cas, à celles obtenues avec la configuration complète à 62 électrodes. Ce résultat suggère que certaines électrodes du montage complet peuvent contenir des informations redondantes ou peu informatives pour la tâche de prédiction de la valence.

Les résultats de la validation croisée à 10 folds indiquent que la configuration à 32 électrodes présente les meilleures performances moyennes et la plus grande stabilité. Cette configuration semble offrir un bon compromis entre richesse de l'information spatiale et réduction du bruit potentiel introduit par certaines électrodes moins pertinentes.

Cependant, l'évaluation réalisée sur l'ensemble de test indépendant montre que la configuration à 16 électrodes peut atteindre des performances légèrement supérieures pour certaines métriques. Cette différence entre les résultats obtenus par validation croisée et ceux observés sur l'ensemble de test peut s'expliquer par les variations naturelles liées à l'échantillonnage des données ainsi que par la capacité du modèle à généraliser différemment selon la partition des données.

Lorsque le nombre d'électrodes est réduit de manière plus agressive (8, 6 et 4 électrodes), une diminution progressive des performances est observée. Cette tendance est attendue, car une réduction trop importante du nombre de capteurs limite la quantité d'information spatiale disponible pour le modèle. Néanmoins, les résultats obtenus montrent que le modèle conserve une capacité de classification relativement stable jusqu'à un certain niveau de réduction.

La comparaison avec les méthodes classiques de sélection d'électrodes (mRMR, ReliefF et SBFS) met également en évidence l'intérêt de l'approche proposée. Contrairement à ces méthodes qui reposent sur des critères statistiques ou heuristiques indépendants du modèle, la stratégie basée sur les poids d'attention permet d'identifier directement les électrodes les plus pertinentes dans le cadre de l'architecture EEGFormer. Cette intégration entre sélection d'électrodes et apprentissage du modèle contribue à améliorer la stabilité et la pertinence des sous-ensembles sélectionnés.

Dans l'ensemble, les résultats obtenus démontrent qu'une réduction significative du nombre d'électrodes peut être réalisée sans compromettre les performances de classification de la valence. Ces observations ouvrent des perspectives intéressantes pour le développement de systèmes EEG plus compacts, plus confortables et plus facilement déployables dans des applications réelles de prédiction de la valence.

En particulier, la réduction du nombre d'électrodes permet d'identifier les canaux les plus pertinents pour la prédiction de la valence, tout en éliminant les électrodes moins utiles ou redondantes. Cette approche contribue à simplifier les systèmes EEG et à faciliter leur utilisation dans des contextes réels, notamment dans le cadre de dispositifs portables.

5.9 VALIDITÉ SCIENTIFIQUE ET MENACES À LA VALIDITÉ

Afin d'assurer la rigueur scientifique des résultats présentés dans ce travail, plusieurs précautions méthodologiques ont été mises en place lors de la conception et de l'évaluation du modèle utilisé. Toutefois, comme dans toute étude expérimentale, certaines limites et menaces potentielles à la validité doivent être considérées.

Tout d'abord, la validité interne des résultats a été renforcée par l'utilisation d'un protocole expérimental rigoureux. Les données ont été séparées en un ensemble d'apprentissage et un ensemble de test indépendant, afin d'éviter toute fuite d'information entre les phases d'apprentissage et d'évaluation. En particulier, l'ensemble de test indépendant représentant 20% du jeu de données a été strictement conservé à part et utilisé uniquement à la fin du processus, après la validation croisée, garantissant ainsi une évaluation impartiale des performances du modèle sur des données jamais vues auparavant.

De plus, une validation croisée stratifiée à 10 folds a été réalisée sur l'ensemble d'apprentissage afin d'évaluer la stabilité et la robustesse des performances du modèle. Cette procédure permet de réduire l'influence d'une partition particulière des données et d'obtenir une estimation plus fiable des performances moyennes.

Concernant la validité externe, il convient de noter que les expériences ont été réalisées sur le jeu de données SEED, qui constitue une référence largement utilisée dans la littérature pour l'étude de la reconnaissance des émotions à partir de signaux EEG. Toutefois, les performances observées dans cette étude pourraient varier lorsqu'elles sont appliquées à d'autres bases de données ou à des conditions expérimentales différentes.

Par ailleurs, la séparation des données a été réalisée au niveau des segments EEG et non au niveau des participants. Ainsi, des segments issus d'un même participant peuvent

être répartis entre les ensembles d'apprentissage et de test. Les résultats obtenus permettent donc d'évaluer la capacité du modèle à généraliser sur de nouveaux segments EEG, mais ne permettent pas de conclure directement sur sa capacité à généraliser à des participants entièrement nouveaux. Une validation inter-sujets pourrait être envisagée dans de futurs travaux afin d'évaluer cet aspect.

Une autre limitation concerne la réduction du nombre d'électrodes. Bien que les résultats montrent qu'une réduction significative est possible sans dégradation majeure des performances, cette observation dépend également des caractéristiques spécifiques du jeu de données utilisé et du protocole d'acquisition EEG.

Enfin, les performances du modèle peuvent être influencées par certains choix de paramètres d'entraînement, tels que les hyperparamètres du modèle ou les stratégies d'optimisation utilisées. Bien que ces paramètres aient été sélectionnés avec soin, d'autres configurations pourraient potentiellement conduire à des résultats différents.

Malgré ces limitations, les résultats obtenus dans cette étude fournissent des indications solides sur la capacité du modèle EEGFormer à maintenir des performances élevées même sous une réduction importante du nombre d'électrodes, tout en offrant une meilleure interprétabilité grâce à l'utilisation des mécanismes d'attention.

CONCLUSION

L'objectif de ce mémoire était d'étudier la possibilité de réduire le nombre d'électrodes EEG nécessaires à la prédiction de la valence émotionnelle tout en conservant un niveau de performance élevé. Cette problématique est particulièrement importante dans le développement de systèmes EEG plus légers et plus facilement déployables dans des contextes réels.

Pour répondre à cet objectif, une approche basée sur l'architecture EEGFormer a été étudiée. Ce modèle intègre des mécanismes d'attention permettant d'extraire des représentations pertinentes à partir des signaux EEG et d'identifier automatiquement les électrodes les plus informatives pour la tâche de classification de la valence.

Les expériences ont été réalisées sur le jeu de données SEED en suivant un protocole expérimental structuré comprenant une séparation des données en ensembles d'entraînement, de validation et de test, ainsi qu'une validation croisée à 10 folds afin d'évaluer la stabilité des performances du modèle.

Les résultats obtenus montrent qu'il est possible de réduire significativement le nombre d'électrodes tout en conservant de bonnes performances de classification de la valence. Les configurations utilisant 32 et 16 électrodes permettent notamment d'obtenir des résultats comparables à ceux obtenus avec la configuration complète de 62 électrodes. La comparaison avec plusieurs méthodes classiques de sélection d'électrodes a également montré l'intérêt de l'approche basée sur les poids d'attention du modèle.

Ces résultats mettent en évidence le potentiel de l'architecture EEGFormer pour l'identification d'électrodes pertinentes dans la prédiction de la valence à partir de signaux EEG, tout en permettant d'envisager des configurations plus compactes et plus adaptées aux applications pratiques.

Certaines limites doivent toutefois être mentionnées. Les expériences ont été réalisées sur un seul jeu de données et dans un contexte expérimental spécifique. De futures recherches pourraient étendre cette étude à d'autres bases de données EEG ou explorer l'intégration d'autres sources d'information physiologique afin d'améliorer encore les performances et la généralisation des modèles.

En conclusion, ce travail montre qu'une réduction importante du nombre d'électrodes EEG peut être envisagée sans compromettre de manière significative les performances de classification de la valence, ouvrant ainsi des perspectives intéressantes pour le développement de systèmes EEG plus compacts et plus accessibles.

BIBLIOGRAPHIE

Aljalal, M., Aldosari, S. A., Molinas, M. & Alturki, F. A. (2024). Selecting EEG Channels and Features Using Multi-Objective Optimization for Accurate MCI Detection. *Scientific Reports*, 14(1), 12483. doi: [10.1038/s41598-024-63180-y](https://doi.org/10.1038/s41598-024-63180-y)

Atyabi, A., Luerssen, M., Fitzgibbon, S. & Powers, D. M. W. (2012). Evolutionary Feature Selection and Electrode Reduction for EEG Classification. Dans *Proceedings of the 2012 IEEE Congress on Evolutionary Computation*, pp. 1–8. doi: [10.1109/CEC.2012.6256130](https://doi.org/10.1109/CEC.2012.6256130)

Chakraborty, B., Ghosh, L. & Konar, A. (2021). Optimal Selection of EEG Electrodes Using Interval Type-2 Fuzzy-Logic-Based Semiseparating Signaling Game. *IEEE Transactions on Cybernetics*, 51(12), 6200–6212. doi: [10.1109/TCYB.2020.2968625](https://doi.org/10.1109/TCYB.2020.2968625)

Ding, Y., Lee, J. H., Zhang, S., Luo, T. & Guan, C. (2025). *Decoding Human Attentive States from Spatial–Temporal EEG Patches Using Transformers*. arXiv preprint arXiv :2502.03736. Repéré à <https://arxiv.org/abs/2502.03736>

Feller, S. & Mohamed, A.-K. (2021). Investigating ICA for EEG Electrode Optimization for the Differentiation Between Right-Hand and Left-Hand Movements. *IFAC-PapersOnLine*, 54(21), 109–114. doi: [10.1016/j.ifacol.2021.12.019](https://doi.org/10.1016/j.ifacol.2021.12.019)

Fitriah, N., Wijaya, S. K., Fanany, M. I., Badri, C. & Rezal, M. (2017). EEG Channels Reduction Using PCA to Increase XGBoost’s Accuracy for Stroke Detection. Dans *AIP Conference Proceedings*, Vol. 1862, p. 030128. doi: [10.1063/1.4991232](https://doi.org/10.1063/1.4991232)

Fonseca, F. S., de Oliveira Silva, A. S., Da Silva, M. E. A., Muniz, M. V. S., de Melo, A. M. N., Machado, W. G., de Sá Moura, C. N. S., Torcate, A. S., de Albuquerque Montenegro, A. C., de Santana, M. A., Gomes, J. C. & Dos Santos, W. P. (2024). Development of an Electrode Reduction Model to Support ASD Diagnosis Based on EEG and Machine Learning. Dans *Proceedings of the 2024 IEEE Latin American Conference on Computational Intelligence (LA-CCI)*, pp. 1–6. doi: [10.1109/LA-CCI62337.2024.10814856](https://doi.org/10.1109/LA-CCI62337.2024.10814856)

Gkintoni, E., Aroutzidis, A., Antonopoulou, H. & Halkiopoulos, C. (2025). From Neural Networks to Emotional Networks : A Systematic Review of EEG-Based Emotion Recognition in Cognitive Neuroscience and Real-World Applications. *Brain Sciences*, 15(3), 220. doi: [10.3390/brainsci15030220](https://doi.org/10.3390/brainsci15030220)

Kheyrkhah, R. & Setarehdan, S. K. (2020). The Impact of Electrode Reduction in the Diagnosis of Dyslexia. Dans *Proceedings of the 2020 International Conference on Biomedical Engineering (ICBME)*, pp. 118–125. doi: [10.1109/ICBME51989.2020.9319431](https://doi.org/10.1109/ICBME51989.2020.9319431)

Mouri, F. I., Valderrama, C. E. & Camorlinga, S. G. (2023). Identifying Relevant Asymmetry Features of EEG for Emotion Processing. *Frontiers in Psychology*, *14*, 1217178. doi: [10.3389/fpsyg.2023.1217178](https://doi.org/10.3389/fpsyg.2023.1217178)

Qu, G., Wang, F., Bi, J., An, Z., Hu, F., Li, H. & Han, S. (2024). A Hybrid Critical Channel Selection Framework for EEG Emotion Recognition. *IEEE Sensors Journal*, *24*(9), 14881–14893. doi: [10.1109/JSEN.2024.3380749](https://doi.org/10.1109/JSEN.2024.3380749)

Tang, C., Gao, T., Li, Y. & Chen, B. (2022). EEG Channel Selection Based on Sequential Backward Floating Search for Motor Imagery Classification. *Frontiers in Neuroscience*, *16*, 1045851. doi: [10.3389/fnins.2022.1045851](https://doi.org/10.3389/fnins.2022.1045851)

Tong, L., Qian, Y., Peng, L., Wang, C. & Hou, Z.-G. (2023). A Learnable EEG Channel Selection Method for MI-BCI Using Efficient Channel Attention. *Frontiers in Neuroscience*, *17*, 1276067. doi: [10.3389/fnins.2023.1276067](https://doi.org/10.3389/fnins.2023.1276067)

Vafaei, E., Nowshiravan Rahatabad, F., Setarehdan, S. K. & Azadfallah, P. (2024). Feature Extraction With Stacked Autoencoders for EEG Channel Reduction in Emotion Recognition. *Basic and Clinical Neuroscience*, *15*(3), 393–402. doi: [10.32598/bcn.2023.5138.2](https://doi.org/10.32598/bcn.2023.5138.2)

Wan, Z., Li, M., Liu, S., Huang, J., Tan, H. & Duan, W. (2023). EEGformer : A Transformer-Based Brain Activity Classification Method Using EEG Signals. *Frontiers in Neuroscience*, *17*, 1148855. doi: [10.3389/fnins.2023.1148855](https://doi.org/10.3389/fnins.2023.1148855)

Wang, Y., Wang, G., Zhou, Y., Li, Z. & Li, Y. (2021). EEG Signal Feature Reduction and Channel Selection Method in Hand Gesture Recognition BCI System. Dans *Proceedings of the 2021 International Conference on Computer Engineering and Application (ICCEA)*, pp. 280–284. doi: [10.1109/ICCEA53728.2021.00062](https://doi.org/10.1109/ICCEA53728.2021.00062)

Xu, H., Wang, X., Li, W., Wang, H. & Bi, Q. (2019). Research on EEG Channel Selection Method for Emotion Recognition. Dans *Proceedings of the 2019 IEEE International Conference on Robotics and Biomimetics (ROBIO)*, pp. 2528–2535. doi: [10.1109/ROBIO49542.2019.8961740](https://doi.org/10.1109/ROBIO49542.2019.8961740)

Zhang, J., Chen, M., Zhao, S., Hu, S., Shi, Z. & Cao, Y. (2016). ReliefF-Based EEG Sensor Selection Methods for Emotion Recognition. *Sensors*, 16(10), 1558. doi: [10.3390/s16101558](https://doi.org/10.3390/s16101558)

Zheng, W.-L. & Lu, B.-L. (2015). Investigating Critical Frequency Bands and Channels for EEG-Based Emotion Recognition with Deep Neural Networks. *IEEE Transactions on Autonomous Mental Development*, 7(3), 162–175. doi: [10.1109/TAMD.2015.2431497](https://doi.org/10.1109/TAMD.2015.2431497)

APPENDICE A

RÉSULTATS DÉTAILLÉS DE LA VALIDATION CROISÉE ET COURBES

D'APPRENTISSAGE

Cette annexe présente les résultats détaillés de la validation croisée à 10 folds obtenus pour les différentes configurations d'électrodes étudiées. Les tableaux suivants rapportent les performances obtenues pour chaque fold en termes d'exactitude, de précision, de rappel, de score F1, de ROC-AUC et de MCC.

Les courbes d'apprentissage associées à certaines configurations représentatives sont également présentées afin d'illustrer l'évolution de la fonction de perte et des performances du modèle au cours de l'entraînement.

A.1 VALIDATION CROISÉE POUR 62 ÉLECTRODES

TABLEAU A.1 : Validation croisée (10 folds) pour 62 électrodes

Fold	Exactitude	Précision	Rappel	Score F1	ROC-AUC	MCC
1	0.845	0.843	0.843	0.843	0.955	0.767
2	0.840	0.839	0.838	0.838	0.955	0.760
3	0.843	0.843	0.841	0.841	0.955	0.764
4	0.863	0.862	0.862	0.862	0.964	0.794
5	0.853	0.852	0.852	0.852	0.958	0.779
6	0.847	0.847	0.846	0.846	0.956	0.771
7	0.793	0.792	0.791	0.792	0.930	0.689
8	0.854	0.853	0.853	0.853	0.958	0.781
9	0.847	0.846	0.846	0.846	0.956	0.771
10	0.855	0.854	0.854	0.854	0.961	0.783

A.2 VALIDATION CROISÉE POUR 48 ÉLECTRODES

TABLEAU A.2 : Validation croisée (10 folds) pour 48 électrodes

Fold	Exactitude	Précision	Rappel	Score F1	ROC-AUC	MCC
1	0.829	0.827	0.827	0.827	0.947	0.743
2	0.850	0.849	0.848	0.848	0.956	0.775
3	0.836	0.834	0.835	0.834	0.949	0.755
4	0.838	0.838	0.837	0.837	0.953	0.758
5	0.834	0.833	0.833	0.832	0.950	0.752
6	0.852	0.850	0.850	0.850	0.958	0.777
7	0.838	0.837	0.836	0.837	0.953	0.757
8	0.846	0.845	0.845	0.845	0.956	0.769
9	0.847	0.846	0.845	0.845	0.957	0.770
10	0.833	0.832	0.831	0.831	0.950	0.750

A.3 VALIDATION CROISÉE POUR 32 ÉLECTRODES

TABLEAU A.3 : Validation croisée (10 folds) pour 32 électrodes

Fold	Exactitude	Précision	Rappel	Score F1	ROC-AUC	MCC
1	0.853	0.852	0.852	0.852	0.957	0.780
2	0.852	0.851	0.851	0.851	0.957	0.778
3	0.847	0.848	0.846	0.846	0.956	0.772
4	0.853	0.851	0.851	0.851	0.957	0.779
5	0.840	0.839	0.839	0.839	0.953	0.760
6	0.850	0.849	0.849	0.849	0.959	0.775
7	0.849	0.848	0.848	0.848	0.959	0.774
8	0.862	0.861	0.861	0.861	0.963	0.793
9	0.860	0.859	0.859	0.859	0.962	0.790
10	0.848	0.847	0.847	0.847	0.957	0.772

A.4 VALIDATION CROISÉE POUR 16 ÉLECTRODES

TABLEAU A.4 : Validation croisée (10 folds) pour 16 électrodes

Fold	Exactitude	Précision	Rappel	Score F1	ROC-AUC	MCC
1	0.839	0.839	0.838	0.838	0.952	0.759
2	0.837	0.835	0.835	0.835	0.949	0.755
3	0.836	0.835	0.835	0.835	0.951	0.755
4	0.839	0.838	0.837	0.837	0.950	0.758
5	0.846	0.846	0.844	0.845	0.956	0.769
6	0.841	0.840	0.840	0.840	0.954	0.762
7	0.825	0.823	0.824	0.823	0.948	0.738
8	0.835	0.834	0.834	0.834	0.948	0.753
9	0.840	0.838	0.838	0.838	0.950	0.759
10	0.841	0.839	0.839	0.839	0.954	0.761

A.5 VALIDATION CROISÉE POUR 8 ÉLECTRODES

TABLEAU A.5 : Validation croisée (10 folds) pour 8 électrodes

Fold	Exactitude	Précision	Rappel	Score F1	ROC-AUC	MCC
1	0.836	0.836	0.835	0.835	0.952	0.754
2	0.838	0.837	0.836	0.836	0.952	0.756
3	0.826	0.825	0.825	0.825	0.947	0.740
4	0.843	0.842	0.842	0.842	0.954	0.765
5	0.850	0.849	0.849	0.849	0.959	0.775
6	0.844	0.842	0.842	0.842	0.956	0.766
7	0.834	0.833	0.833	0.833	0.948	0.751
8	0.844	0.843	0.843	0.843	0.956	0.767
9	0.835	0.833	0.834	0.834	0.952	0.753
10	0.841	0.839	0.839	0.839	0.952	0.761

A.6 VALIDATION CROISÉE POUR 6 ÉLECTRODES

Le Tableau A.6 présente les résultats détaillés de la validation croisée à 10 folds pour la configuration à 6 électrodes.

TABLEAU A.6 : Validation croisée (10 folds) pour 6 électrodes

Fold	Exactitude	Précision	Rappel	Score F1	ROC-AUC	MCC
1	0.816	0.815	0.814	0.814	0.942	0.724
2	0.813	0.812	0.811	0.811	0.941	0.720
3	0.811	0.810	0.809	0.810	0.940	0.717
4	0.831	0.829	0.829	0.829	0.948	0.746
5	0.826	0.824	0.824	0.824	0.947	0.739
6	0.825	0.823	0.823	0.824	0.946	0.738
7	0.825	0.824	0.823	0.824	0.946	0.737
8	0.820	0.818	0.818	0.818	0.946	0.730
9	0.820	0.819	0.818	0.819	0.944	0.730
10	0.824	0.822	0.822	0.822	0.947	0.735

A.7 VALIDATION CROISÉE POUR 4 ÉLECTRODES

Le Tableau A.7 présente les résultats détaillés de la validation croisée à 10 folds pour la configuration à 4 électrodes.

TABLEAU A.7 : Validation croisée (10 folds) pour 4 électrodes

Fold	Exactitude	Précision	Rappel	Score F1	ROC-AUC	MCC
1	0.796	0.793	0.794	0.793	0.931	0.693
2	0.792	0.790	0.790	0.790	0.930	0.688
3	0.795	0.794	0.793	0.793	0.932	0.692
4	0.805	0.803	0.803	0.803	0.936	0.708
5	0.808	0.806	0.806	0.806	0.937	0.712
6	0.803	0.803	0.801	0.802	0.935	0.705
7	0.798	0.796	0.796	0.796	0.932	0.697
8	0.789	0.787	0.787	0.787	0.931	0.684
9	0.790	0.789	0.788	0.788	0.931	0.685
10	0.800	0.798	0.798	0.798	0.934	0.700

A.8 COURBES D'APPRENTISSAGE DU MODÈLE

Les figures suivantes illustrent des exemples représentatifs de courbes d'apprentissage obtenues lors de la validation croisée à 10 folds. Pour des raisons de lisibilité, un seul fold représentatif est présenté pour chaque configuration d'électrodes.

La Figure A.1 présente les courbes d'apprentissage pour la configuration complète à 62 électrodes. Les Figures A.2, A.3 et A.4 illustrent des configurations intermédiaires, tandis que les Figures A.5, A.6 et A.7 correspondent aux configurations les plus réduites.




FIGURE A.1 : Courbes d'apprentissage du modèle EEGFormer pour la configuration à 62 électrodes




FIGURE A.2 : Courbes d'apprentissage du modèle EEGFormer pour la configuration à 48 électrodes




FIGURE A.3 : Courbes d'apprentissage du modèle EEGFormer pour la configuration à 32 électrodes.




FIGURE A.4 : Courbes d'apprentissage du modèle EEGFormer pour la configuration à 16 électrodes.




FIGURE A.5 : Courbes d'apprentissage du modèle EEGFormer pour la configuration à 8 électrodes.




FIGURE A.6 : Courbes d'apprentissage du modèle EEGFormer pour la configuration à 6 électrodes.




FIGURE A.7 : Courbes d'apprentissage du modèle EEGFormer pour la configuration à 4 électrodes.