

الجمهورية الجزائرية الديمقراطية الشعبية
RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE
وزارة التعليم العالي و البحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

ÉCOLE NATIONALE POLYTECHNIQUE



المدرسة الوطنية المتعددة التقنيات
Ecole Nationale Polytechnique

Département d'Automatique

Mémoire de projet de fin d'études pour l'obtention du diplôme d'ingénieur d'état en
automatique

Prédiction de l'Indice Bi-Spectral par les techniques de Deep Learning - Monitoring de la profondeur de l'anesthésie

Auteure :

LADJADJ Katia

Présenté et soutenu le 08/07/2021, devant les membres du jury :

Président	Djamel	BOUKHETALA	Prof.	ENP, Algerie
Promoteur	Mohamed	TADJINE	Prof.	ENP, Algerie
Promoteur	Messaoud	CHAKIR	PhD.	ENP, Algerie
Examineur	Hakim	ACHOUR	PhD.	ENP, Algerie

ENP 2021

École Nationale Polytechnique (ENP)
10, Avenue des Frères Oudek, Hassen Badi, BP. 182, 16200 El Harrach, Alger, Algérie
www.enp.edu.dz

الجمهورية الجزائرية الديمقراطية الشعبية
RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE
وزارة التعليم العالي و البحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

ÉCOLE NATIONALE POLYTECHNIQUE



المدرسة الوطنية المتعددة التقنيات
Ecole Nationale Polytechnique

Département d'Automatique

Mémoire de projet de fin d'études pour l'obtention du diplôme d'ingénieur d'état en
automatique

Prédiction de l'Indice Bi-Spectral par les techniques de Deep Learning - Monitoring de la profondeur de l'anesthésie

Auteure :

LADJADJ Katia

Présenté et soutenu le 08/07/2021, devant les membres du jury :

Président	Djamel	BOUKHETALA	Prof.	ENP, Algerie
Promoteur	Mohamed	TADJINE	Prof.	ENP, Algerie
Promoteur	Messaoud	CHAKIR	PhD.	ENP, Algerie
Examineur	Hakim	ACHOUR	PhD.	ENP, Algerie

ENP 2021

École Nationale Polytechnique (ENP)
10, Avenue des Frères Oudek, Hassen Badi, BP. 182, 16200 El Harrach, Alger, Algérie
www.enp.edu.dz

ملخص - إن مراقبة عمق التخدير أمر مهم للغاية أثناء أي عملية ، ومؤشر (*bispectral*(BIS)) هو واحد من العديد من التقنيات المستخدمة لرصد هذه الظاهرة ، وهو يعتمد على التحليل الحسابي لإشارات EEG . في هذا العمل ، سوف نستخدم طرق التعلم الآلي للتنبؤ بـ *BIS* من خلال اقتراح نهجين. الأول يعتمد على مجموعة من خوارزميات تحسين التدرج التي تتعلم من البيانات المستمدة من إشارات EEG . الثاني يستخدم شبكة LSTM العصبية متبوعة بشبكة تغذية للتنبؤ بـ *BIS* من تاريخ جرعات عوامل التخدير. تظهر النتائج أداء نماذجنا بمتوسط خطأ تربيعي 4.6 لنهج التعلم الآلي و 3.9 لنهج التعلم العميق.

كلمات مفتاحية - EEG ، توقع ، *BIS* ، التعلم العميق ، LSTM ، PK - PD .

Abstract— Monitoring the depth of anesthesia is very important during any operation. The bispectral index (BIS) is one of the many technologies used to monitor this phenomenon, it is based on an algorithmic analysis of EEG signals. In this work, we will use artificial intelligence learning methods to predict BIS by proposing two approaches. The first is based on a stack of gradient boosting algorithms that learn from data drawn from EEG signals. The second uses an LSTM neural network followed by a feedforward network to predict BIS from dosing histories of anesthetic agents. The results show the performance of our models with a mean squared error of 4.6 for the machine learning approach and 3.9 for the deep learning approach.

Index-terms : Deep learning, Machine learning, BIS prediction, EEG, LSTM, PK-PD model.

Résumé— La surveillance de la profondeur de l'anesthésie est très importante pendant toute opération, L'indice bispectral (BIS) est l'une des nombreuses technologies utilisées pour surveiller ce phénomène, il se base sur une analyse algorithmique des signaux EEG. Dans ce travail, nous allons utiliser les méthodes d'apprentissage automatique afin de prédire le BIS en proposant deux approches. La première se base sur un empilement d'algorithmes de renforcement de gradient qui apprend à partir des données tirées des signaux EEG. La seconde utilise un réseau neuronal LSTM suivi d'un réseau feedforward afin de prédire le BIS depuis les historiques de dosages des agents anesthésiants. Les résultats montrent les performances de nos modèles avec une erreur quadratique moyenne de 4.6 pour l'approche avec apprentissage machine et 3.9 pour l'approche avec l'apprentissage profond.

Mots-clés : Apprentissage profond, Apprentissage machine, prédiction BIS, EEG, LSTM, modèle PK-PD.

Remerciement

Tout d'abord, je remercie Dieu pour m'avoir guidé et donné la force et le courage nécessaire pour l'accomplissement de mon travail.

Ensuite, je remercie mes deux encadreurs M. TADJINE et M. CHAKIR pour l'aide qu'ils m'ont apporté tout au long de mon projet.

Je tiens également à remercier les membres du jury, M. BOUKHETALA et M. ACHOUR pour avoir accepté d'examiner mon travail et de l'enrichir avec leurs propositions.

Je remercie aussi ma famille et mes amis pour leur soutien et leur aide continue.

Enfin, mes remerciements s'adressent à toute personne ayant participé de près ou de loin à la réalisation de ce travail.

Dédicace

Je dédie ce travail d'abord à mes chers parents, merci pour votre soutien et votre confiance indéfectible.

A ma soeur adorée, Sonia, merci de toujours me pousser vers l'avant et pour tes encouragements.

A Yasmine, pour avoir toujours été derrière moi pendant toutes ces années.

A Omar, merci d'être là pour moi au quotidien.

A Amine avec qui j'ai partagé toute l'aventure Polytech.

A Younes et mes camarades en Automatique.

Table des matières

Liste des Tableaux

Liste des Figures

Introduction	13
1 L'indice Bispectral	15
1.1 Introduction	16
1.2 Définition	16
1.3 Signaux EEG	17
1.4 Calcul du BIS	18
1.4.1 Acquisition des signaux	18
1.4.2 Numérisation	19
1.4.3 Filtrage des artefacts	19
1.4.4 Calcul des paramètres	20
1.4.5 Paramètres influant sur le BIS	21
1.5 Limites de l'indice Bispectral	23
1.6 Etat de l'art	24
1.6.1 Algorithmes d'apprentissage courants	25
1.6.2 Système d'inférence Neuro-Adaptative (Adaptive neuro-fuzzy inference system ANFIS)	26
1.6.3 Le modèle pharmacocinétique/pharmacodynamique (PK/PD)	27
1.7 Conclusion	30
2 Ensemble de données (Dataset)	31
2.1 Introduction	32
2.2 Difficultés	32
2.3 Présentation du dataset	32
2.4 Acquisition et enregistrement des données	33

2.5	Sélection des données	35
2.6	Téléchargement des données	36
2.7	Traitement des données	36
2.8	Conclusion	38
3	Méthodologies	39
3.1	Introduction	40
3.2	Apprentissage machine	40
3.2.1	Rappel sur la méthode du gradient	40
3.2.2	Le renforcement de gradient (Gradient Boosting)	40
3.2.3	Modèle CatBoost	43
3.2.4	Modèle LightGBM	43
3.2.5	Modèle XGBoost	44
3.2.6	Modèle RandomForrest	44
3.3	L'empilement des modèles (Model Stacking)	45
3.3.1	Validation croisée	45
3.3.2	Processus d'empilement	46
3.4	Apprentissage profond	47
3.4.1	Réseaux de neurones artificiels	47
3.4.2	Fonctions d'activation	49
3.4.3	Réseaux de neurones à propagation avant	51
3.4.4	Entraînement d'un réseau de neurones	52
3.4.5	Réseaux de neurones récurrents RNN	53
3.4.6	Réseau récurrent à mémoire courte (Long-Short Term Memory LSTM)	55
3.5	Apprentissage par transfert (Transfer Learning)	57
3.6	Conclusion	57
4	Implémentation et résultats	58
4.1	Introduction	59
4.2	Matériel software	59
4.2.1	Google Colaboratory	59
4.2.2	Keras	59
4.3	Critères d'évaluation	59
4.3.1	Racine de l'erreur quadratique moyenne (RMSE)	59
4.3.2	Médiane de l'erreur de performance (MDPE)	60
4.3.3	Médiane de l'erreur de performance absolue (MDAPE)	60
4.4	Modèle Gradient Boosting	60
4.4.1	Architecture	60

4.4.2	Résultats	60
4.5	Modèle Deep Learning (LSTM+feedforward network)	61
4.5.1	Architecture	61
4.5.2	Résultats	63
4.6	Discussion	64
4.7	Conclusion	64
Conclusion		66
5	Annexe A	71
Annexe A		71
5.1	EEG	72
5.1.1	Introduction	72
5.1.2	Qu'est ce que les signaux EEG?	72
5.1.3	Système d'acquisition des signaux EEG	72
5.2	Placement des électrodes	73
5.3	Montages EEG communs	74
5.3.1	Montage bipolaire	74
5.3.2	Montage référentiel	75
5.3.3	Montage de référence moyen	76
5.4	Fondamentaux des ondes EEG	76
5.4.1	Ondes Delta (jusqu'à 4 Hz)	77
5.4.2	Ondes Thêta (4-8 Hz)	77
5.4.3	Ondes Alpha (8-12Hz)	77
5.4.4	Ondes Bêta (12-30 Hz)	78
5.4.5	Ondes Gamma (au-dessus de 30 Hz)	78
5.5	Techniques d'analyse des signaux EEG	78
5.5.1	Méthodes du domaine temporel	78
5.5.2	Méthodes du domaine fréquentiel	79
5.5.3	Méthodes du domaine temps-fréquence	79
5.5.4	Méthodes non linéaires	79

Liste des Tableaux

1.1	L'indice Bispectral et son degré de sédation	17
2.1	Description des données utilisées dans la première version du dataset	35
2.2	Paramètres ajoutés pour former la seconde version du dataset	36
4.1	Résultats approche Gradient Boosting	61
4.2	Résultats Modèle deep learning	63

Liste des Figures

1.1	Rythmes cérébraux	18
1.2	Équipement pour le monitoring de l'indice bispectral [5]	19
1.3	Paramètres générant le BIS [4]	22
1.4	Structure d'un arbre de décision [8]	26
1.5	Architecture ANFIS [9]	27
1.6	Modèle PK [12]	28
1.7	Modèle PD [12]	29
1.8	Modèle PK/PD [11]	30
2.1	Schéma d'obtention des données de VitalDB [13]	33
2.2	Organigramme de données	34
2.3	Schéma d'obtention des données de VitalDB [13]	35
3.1	Comparaison de développement d'arbre de décision pour XGBoost et LightGBM [21]	44
3.2	Schéma de la forêt aléatoire [23]	45
3.3	Méthode de validation croisée K-fold [25]	46
3.4	Couches des piles de modèles [24]	47
3.5	Schéma d'un neurone artificiel	48
3.6	Architecture d'un réseau de neurones [27]	49
3.7	graphe de la fonction sigmoïde	50
3.8	graphe de la fonction tanh	50
3.9	graphe de la fonction ReLU	51
3.10	Exemple d'un réseau de neurones Feed-Forward	52
3.11	Comparaison entre un réseau de neurones récurrent (à gauche) et un réseau de neurones feedforward (à droite)	53
3.12	RNN standard [30]	54
3.13	Architecture standard d'un LSTM [30]	55
4.1	Comparaison entre les modèles de la première approche	61

4.2	Structure du modèle deep learning	63
4.3	Comparaison entre les deux approches	64
5.1	Enregistrement de signaux EEG	73
5.2	Le système international de placement des électrodes 10-20	74
5.3	Illustration d'un montage bipolaire	75
5.4	Illustration d'un montage référentiel où A2 est l'électrode de référence	75
5.5	Illustration d'un montage référentiel moyen	76
5.6	Signal EEG et ses bandes de fréquences correspondantes	77

Acronymes

ANFIS Adaptive Neuro-Fuzzy Inference System. 26, 27

ANN Artificial Neural Network. 48

ApEn Approximate Entropy. 79

AR Auto-regressive. 79

ARMA Auto-Regressive Moving Average. 79

BIS Bispectral Index. 16, 17, 22, 23, 30, 35, 60, 65

BPTT Backpropagation through time. 53

BSR Burst Suppression Ratio. 21

CEC Circulation Extracorporelle. 20, 23

ECG Electrocardiogramme. 20

ECoG Electrocorticogramme. 73

EEG Electroencephalogramme. 16–18, 20, 23, 32, 73, 76, 78, 79

EFB Exclusive Feature Bundling. 43, 44

EMG Electromyogram. 22

ETAG End-Tidal Anesthetic Gas. 24

FDA Food and Drug Administration. 17, 24

FFT Fast Fourier Transform. 20

FL Fuzzy Logic. 26

FT Fourier Transform. 79

GOSS Gradient based One Side Sampling. 43, 44

GPU Graphical Processing Unit. 59

HOS High Order Spectra. 79

ICA Independant Component Analysis. 78, 79

LDA Linear Discriminant Analysis. 78, 79

LLE Largest Laypunov Exponent. 79

LSTM Long Short-Term Memory. 55–57, 61, 62, 65

MA Moving Average. 79

MDAPE Median Absolute Performance Error. 60

MDPE Median Performance Error. 60

MSE Mean Squarred Error. 26

NN Neural Network. 26, 47

PCA Principal Component Analysis. 78

PD Pharmacodynamics. 27, 29, 62, 65

PK Pharmacokinetics. 27, 28, 62, 65

PSD Power Spectrum Density. 79

RBR Relative Beta Ratio. 21

ReLU Rectified Linear Unit. 50, 51, 62

RMSE Root Mean Squarred Error. 59, 64

RNN Recurrent Neural Network. 53–55

SEF Spectral Edge Frequency. 23

SFS SynchFastSlow. 21

SQI Signal Quality Index. 22, 24, 37

SVM Support Vector Machine. 25

TP Total Power. 22

TPU Tensor Processing Unit. 59

WT Wavelet Transform. 79

Introduction

La surveillance de la profondeur de l'anesthésie est très importante pendant toute procédure, car une anesthésie trop profonde peut provoquer des changements hémodynamiques. Une anesthésie trop légère comporte le risque de rappel ou de prise de conscience pendant l'anesthésie. La prise de conscience pendant l'anesthésie est une complication très grave avec des séquelles psychologiques potentielles à long terme telles que l'anxiété et les troubles post-traumatiques.[1]

L'indice bispectral (BIS) est l'une des nombreuses technologies utilisées pour surveiller la profondeur de l'anesthésie. Dans les années 1990, la société de dispositifs médicaux Aspect Medical Systems a lancé un effort de recherche pour développer l'électroencéphalogramme comme moyen de surveiller la profondeur de l'anesthésie, en prenant le signal EEG complexe et en traitant le résultat en un seul nombre, fournissant ainsi à l'anesthésiste une indication numérique de la profondeur de l'anesthésie. [2] Le moniteur BIS quantifie les effets anesthésiques sur le cerveau, en particulier la composante hypnotique de l'anesthésie.

L'électroencéphalographie (EEG) est une technique non-invasive et non-coûteuse qui enregistre l'activité électrique produite par le cerveau avec une bonne résolution temporelle et l'analyse algorithmique de ces signaux a permis d'introduire l'indice bispectral comme nouvelle mesure du niveau de conscience d'un patient pendant une anesthésie générale.

L'utilisation du BIS dans les hôpitaux en salle d'opérations et en soins intensifs a permis de réduire le temps nécessaire à l'extubation et le temps de récupération ainsi que de diminuer le risque de nausées et de vomissements post-opératoire. Une économie en quantité d'agents anesthésiants a également été remarquée.

Les détails exacts de l'algorithme utilisé pour créer l'indice BIS n'ont pas été divulgués par la société qui l'a développée. Par conséquent, un grand nombre de travaux et recherches se sont attelés à la tâche d'émuler cet indice, que ce soit par des méthodes d'apprentissage automatique ou par une approximation par modèle mathématique.

Dans ce travail, nous allons essayer de concevoir notre propre modèle de prédiction de l'indice bispectral. Pour cela, nous testons deux approches :

- Régression en utilisant des algorithmes d'apprentissage machine se basant sur le renforcement de gradient en utilisant les données extraites des signaux EEG disponibles sur le moniteur du BIS.
- Proposer une architecture d'apprentissage profond en utilisant un réseau de neurones LSTM suivi d'un réseau feedforward sensé simuler le modèle mathématique PK-PD en utilisant les historiques de dosage d'anesthésiants comme données d'entraînement.

Organisation du mémoire

Dans le premier chapitre, nous définissons l'indice bispectral en expliquant en détail son origine, son utilisation, sa méthode de calcul ainsi que ses limitations. Nous dresserons ensuite un état de l'art sur les différents travaux effectués pour la prédiction de cet indice en passant par les algorithmes d'apprentissage automatique aux modèles mathématiques développés.

Le second chapitre souligne les difficultés à trouver un bon ensemble de données dans ce domaine puis présente le dataset dont nous disposons, détaille les étapes pour l'obtention de ce dernier ainsi que le traitement que ces données ont subi.

Le troisième chapitre donne les notions de bases de l'apprentissage machine et l'apprentissage profond nécessaires à la compréhension des modèles proposés pour répondre à la problématique.

Enfin, le quatrième chapitre porte sur l'implémentation de nos modèles et la présentation des résultats obtenus. Les critères d'évaluation des performances de ces modèles sont également exposés.

Chapitre 1

L'indice Bispectral

1.1 Introduction

La conscience peropératoire avec rappel, bien que rare, est une complication pénible de l'anesthésie générale qui est associée à des séquelles psychologiques importantes. Depuis l'introduction du curare et d'autres médicaments bloquants neuromusculaires, la sensibilisation peropératoire est devenue une préoccupation anesthésique importante. Comme cela est devenu une préoccupation majeure, un certain nombre de méthodologies et de dispositifs ont été mis en œuvre lors d'une anesthésie générale, dans l'espoir de prévenir le développement de cette complication pénible. Ces méthodologies vont de la surveillance des signes cliniques suggérant une prise de conscience (c.-à-d. tachycardie, hypertension, larmolement et transpiration) à l'utilisation de moniteurs d'électroencéphalographie (EEG) pour mesurer l'activité cérébrale. L'indice bispectral est d'ailleurs tiré de ces derniers et est une image de la profondeur de l'anesthésie et de l'état de conscience d'un patient. Dans ce chapitre nous allons commencer par une présentation détaillée de l'indice bispectral puis nous exposerons les différentes méthodes utilisées pour l'émulation et le contrôle de cet indice.

1.2 Définition

L'indice bispectral est un paramètre calculé à partir des signaux de l'électroencéphalogramme (EEG) d'un patient. Sa valeur donne une estimation de l'état de conscience durant une anesthésie et sert de guide pour les doses d'agents anesthésiques à administrer afin de garder l'état stable requis pour l'opération. La valeur du BIS peut aller de 0 (aucune activité cérébrale) à 100 (sujet totalement éveillé).[1] Lors d'une anesthésie générale, deux aspects principaux sont à prendre en compte :

L'aspect "sommeil" : qui correspond à la perte de conscience du patient, ainsi que l'absence de mémorisation et de la réponse aux ordres.

L'aspect analgésique : qui correspond à l'absence de réactivité face aux stimulations douloureuses.

L'anesthésie doit donc être adaptée et équilibrée afin de couvrir ces deux aspects en évitant les cas de sous-dosage et de sur-dosage. Le sous-dosage peut conduire à un état de conscience durant l'opération, causant un traumatisme et des séquelles psychologiques sur le patient telles que l'anxiété, des troubles du sommeil et un trouble post-traumatique. Quant au surdosage, celui-ci peut provoquer des changements hémodynamiques et causer des effets secondaires importants (hypotension, bradycardie)[3].

Afin de parer à ces possibilités, et comme l'évaluation clinique de l'anesthésie reste insuffisante, surtout compte tenu de la complexité des besoins et de la tolérance des patients, l'indice bi-spectral est venu répondre au besoin de "mesurer" de manière objective et efficace, le niveau d'anesthésie d'un patient.

Lorsqu'un patient est éveillé son BIS est supérieur à 90, l'administration d'agents anesthésiques le fait décroître et lorsqu'il descend en dessous de la barre des 75, on considère que le patient n'a plus la faculté de mémorisation. Il ne peut également plus répondre aux ordres simples avec un BIS en dessous de 50 [3]. Compte tenu de ces résultats, il a été établi que pour une anesthésie générale adéquate pour une opération chirurgicale, le BIS devait être maintenu à des valeurs se trouvant entre 40 et 60.

BIS	Sedation Degree
90-100	Awaken
70-90	Light to moderate sedation
60-70	Superficial Anesthesia
40-60	Adequate Anesthesia
0-40	Deep Anesthesia

Table 1.1 – L'indice Bispectral et son degré de sédation

L'utilisation du BIS (avec un moniteur spécifique) est la première méthode approuvée par la FDA afin de déterminer l'état de conscience d'un patient et a montré plusieurs avantages, tels que la réduction de la période de récupération anesthésique, la réduction de la consommation de médicaments anesthésiques, la diminution du dysfonctionnement cognitif postopératoire et la stratification du risque périopératoire.

1.3 Signaux EEG

L'électroencéphalographie (EEG) est une technique indolore et non invasive d'imagerie fonctionnelle du cerveau. Elle mesure l'activité électrique générée par les cellules nerveuses par le biais d'électrodes placées sur le cuir chevelu. L'électroencéphalogramme est la transcription sous forme d'un tracé des variations dans le temps de l'activité électrique du cerveau.

Cette activité électrique est représentée par des ondes avec des fréquences et des amplitudes variables. Il est ensuite déconstruit par transformation de Fourier dans les formes d'onde communément reconnues avec des gammes de fréquences distinctes : δ ($\leq 4\text{Hz}$), θ (4Hz-8Hz), α (8Hz,12Hz), β (12Hz-30Hz) et γ ($\geq 30\text{Hz}$) où chacune d'entre elles est associée à un état de sommeil différent.




Figure 1.1 – Rythmes cérébraux

Afin d’extraire de l’information et d’interpréter les signaux, des études quantitatives sont effectuées sur ces derniers.

Analyse du domaine temporel : description du comportement et du changement du modèle au fil du temps

Analyse du domaine fréquentiel : description des signaux EEG en fonction de la fréquence.(Voir annexe en 5.1)

1.4 Calcul du BIS

Le BIS (indice bispectral) est un indice dérivé de manière empirique et dépendant de la mesure de la « cohérence » entre les composants de l’électroencéphalogramme quantitatif (EEG)[4], son obtention passe par plusieurs étapes.

1.4.1 Acquisition des signaux

Dans le processus de calcul BIS, la première étape est l’acquisition des signaux EEG, qui se fait par l’application de quatre électrodes placées sur la surface de la peau qui permettent une conduction électrique appropriée avec une faible impédance.




Figure 1.2 – Equipement pour le monitoring de l'indice bispectral [5]

Le montage utilisé est le référentiel unilatéral avec électrode exploratrice en région fronto-temporale (position FT9 ou FT10) et électrode de référence en région frontopolaire (position FPz). Ceci détermine que la linéation EEG obtenue est monocanal (gauche ou droite, selon la position de l'électrode fronto-temporale). L'électrode en position FT8 est utilisée dans l'algorithme BIS pour augmenter son calcul en présence d'activité électromyographique, et l'électrode FP2 (masse virtuelle) a pour but d'augmenter la réjection du mode commun. (Voir annexe en 5.1)

1.4.2 Numérisation

La numérisation est effectuée après acquisition et amplification du signal EEG. Le signal analogique capté est présenté à intervalles réguliers (fréquence exprimée en Hz) de sorte que les déflexions de chaque onde sont définies par une série de valeurs concrètes positives ou négatives dépendant du moment de la collecte des données.

La fréquence des données collectées est essentielle pour obtenir un signal numérisé sûr car, selon le théorème de Shannon, elle doit être supérieure au double de la fréquence maximale du signal analysé. Si la fréquence des échantillons est faible, il y a un risque de convertir par erreur, une onde analogique rapide en une onde numérisée lente (effet d'aliasing).

1.4.3 Filtrage des artefacts

Après numérisation, le signal subit un processus de reconnaissance d'artefacts. Les artefacts produits par des signaux qui ont dépassé la limite dynamique de l'amplificateur, comme l'utilisation d'un scalpel électrique, peuvent être identifiés dans l'époque (divisions temporelles finies d'enregistrement, dans lesquelles l'analyse est faite : deux secondes de durée dans le cas BIS) les

données originales ne peuvent pas être reconstituées.

D'autres artefacts peuvent être éliminés du signal contaminé et le signal filtré résultant peut être utilisé pour une analyse plus approfondie. Ces types d'artefacts incluent ceux qui ont des fréquences supérieures à l'EEG (par exemple, le courant électrique alternatif). D'autres artefacts dont la fréquence se situe dans la limite des ondes EEG, comme l'ECG et ceux produits par les pompes rotatives (CEC) sont éliminés. D'autres contaminants détectables sont les interférences produites par les stimulateurs des nerfs périphériques ainsi que celles émises par les stimulateurs des potentiels évoqués. Chez les patients éveillés ou avec une sédation superficielle, les mouvements oculaires créent une activité ondulatoire lente et reconnaissable.

Dans le cas spécifique de BIS, l'EEG numérisé est filtré pour exclure les artefacts de hautes et basses fréquences et divisé en fenêtres temporelles de deux secondes. Chaque fenêtre est corrélée à un modèle d'électrocardiogramme (ECG) et si des spicules de stimulateur cardiaque ou des signaux ECG sont affichés, ils seront éliminés et les données perdues seront estimées par interpolation. Les mouvements du globe oculaire sont détectés et les données contaminées par cet artefact sont rejetées.

Par la suite, la ligne de base est analysée et les tensions contaminantes sont éliminées en raison des basses fréquences (par exemple, le bruit basse fréquence des électrodes).

1.4.4 Calcul des paramètres

Le signal EEG après numérisation et filtration des artefacts peut être traité mathématiquement. Cependant, à ce moment, les modifications de tension ne peuvent être évaluées que dans le domaine temporel. A partir de ces paramètres (tension et temps), et en prenant en compte que l'EEG est un signal stochastique et certains points statistiques ne sont pas prévisibles (les valeurs futures ne peuvent être prédites qu'en raison d'une probabilité de distribution des amplitudes observées dans le signal), de nombreuses analyses statistiques peuvent être effectuées résultant en des variables importantes.

Avant d'effectuer une analyse fréquentielle et pour éviter les erreurs dans l'interprétation ultérieure des ondes, chaque époque est analysée selon la fenêtre de Blackman, ce qui réduit les distorsions liées à la contamination par des artefacts de fréquence créés par des transitions abruptes dans chaque époque.

Après la numérisation du signal et l'application de la fonction de fenêtre de Blackman, la même chose peut être traitée mathématiquement par analyse de Fourier. Dans les moniteurs cliniques, l'EEG est décomposé en son spectre de fréquences par la transformée de Fourier rapide (FFT) de Cooley et Tukey. Cet algorithme permet un calcul efficace des données numérisées et est présenté graphiquement sous la forme d'un histogramme de puissance dans le domaine fréquentiel dont différents paramètres sont dérivés.

1.4.5 Paramètres influant sur le BIS

L'analyse temporelle et fréquentielle de l'électroencéphalographie nous donne les sous-paramètres principaux qui influent sur le calcul du BIS [6] :

- Burst Suppression Ratio (BSR) : issu de l'analyse temporelle des signaux EEG, il est défini comme la période d'EEG «entièrement supprimée», c'est à dire les intervalles de plus de 0,5 seconde dans laquelle l'EEG est isoélectrique (ne dépasse pas $\pm 0,5 \mu\text{V}$).Ce rapport augmente à mesure que le cerveau devient de plus en plus inactif.
- QUAZI Suppression Index : résultat d'une analyse temporelle, c'est la période d'EEG «presque supprimée», cet indice permet de détecter des périodes de suppression qui n'ont pas été couvertes par le BSR. La méthode de calcul de ce paramètre n'a pas été divulguée.
- Relative Ratio : défini comme le degré d'activation haute fréquence il est une mesure de la proportion de la puissance du signal dans la plage de fréquences haute / moyenne et est calculé comme suit :

$$RBR = \log_{10}(P_{30--47\text{Hz}}/P_{11--20\text{Hz}}) \quad (1.1)$$

Avec P la puissance spectrale dans la bande EEG

- SynchFastSlow (SFS) : ce paramètre quantifie la puissance bispectrale relative dans la bande de fréquences 40–47 Hz et est calculé comme suit :

$$SFS = \log_{10}(B_{0.5--47\text{Hz}}/B_{40--47\text{Hz}}) \quad (1.2)$$

Avec B la puissance bispectrale dans la bande EEG.

L'indice bispectral est ensuite calculé par un modèle statistique multivariable utilisant des fonctions non linéaires de sous-paramètres. Cet algorithme est cependant exclusif, c'est-à-dire que le propriétaire n'en a pas divulgué l'entièreté.

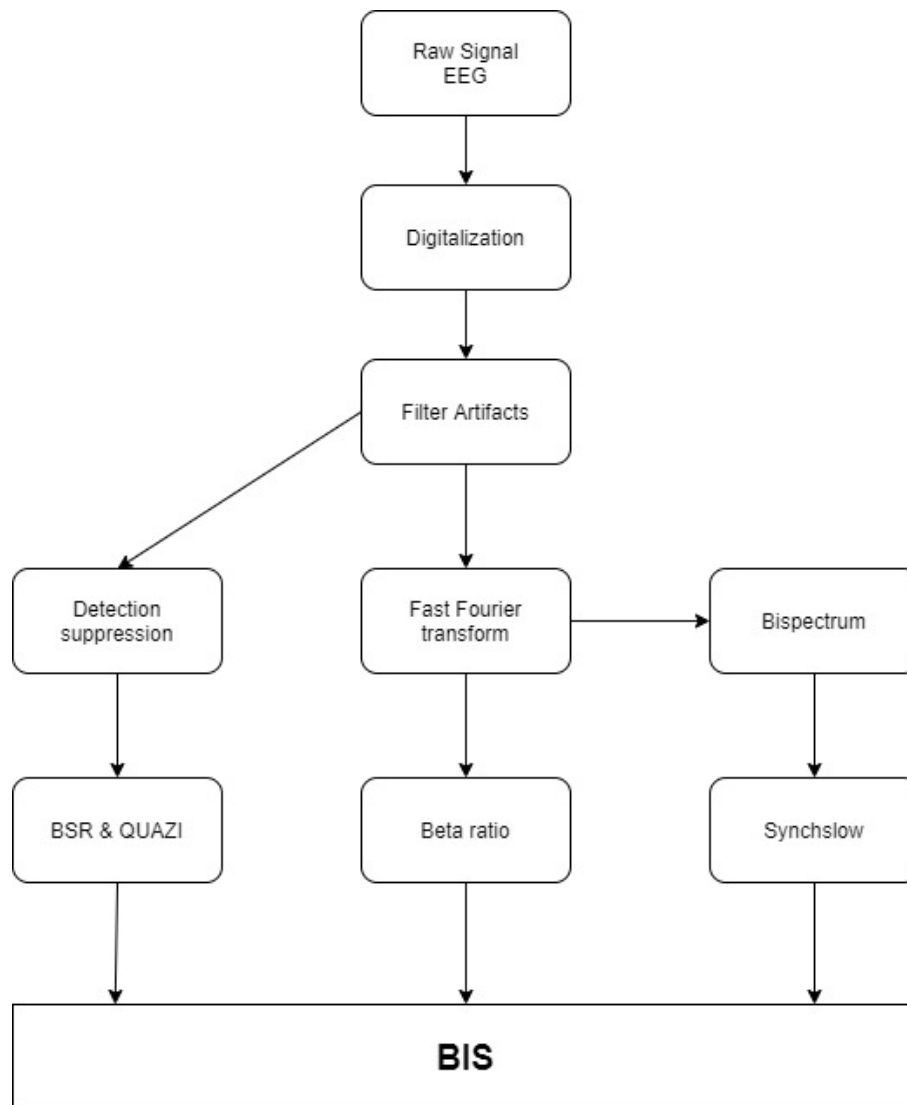


Figure 1.3 – Paramètres générant le BIS [4]

Il existe également d'autres paramètres, qui apparaissent sur l'écran du moniteur et dont les valeurs ont une incidence sur le BIS

- Electromyogram (EMG) : Mesure de l'activité musculaire
- Suppression Ratio () : Proportion d'une période de 63 secondes au cours de laquelle l'activité EEG a été supprimée (c'est-à-dire isoélectrique). Cette valeur est inversement proportionnelle à la valeur BIS.
- Signal Quality Index (SQI) : Représente la fiabilité et la qualité des signaux EEG, avec 100 % représentant une qualité de signal parfaite et 0 % de mauvaise qualité de signal.
- Énergie Totale (TP) : Somme de la puissance des différentes ondes composantes du signal.

- SEF95 (95th percentile of spectral edge frequency) : Fréquence en dessous de laquelle se situe 95% de la puissance EEG totale. Cette valeur diminue avec l'augmentation des niveaux d'anesthésiques généraux ou d'opioïdes.

1.5 Limites de l'indice Bispectral

Le BIS est à ce jour le seul moniteur de sommeil anesthésique disponible sur le marché et adapté à une utilisation en anesthésie, celui-ci est actuellement le plus utilisé dans les salles d'opération, les unités de soins intensifs et certains services d'urgence. Cependant, il existe des limitations au BIS qui sont résultats de différents facteurs [1] :

1. Agents anesthésiques : Les agents anesthésiques utilisés affectent les valeurs du BIS. Un patient anesthésié avec un médicament anesthésique peut être dans un état d'inconscience plus profond qu'un autre patient avec le même score anesthésié avec une combinaison différente de médicaments. Le moniteur BIS n'est pas fiable avec certains anesthésiques, tels que la kétamine et le protoxyde d'azote (NO). En 2017, Mishra et al. ont étudié l'effet du protoxyde d'azote sur l'indice bispectral et ont découvert que la valeur BIS augmente avec l'ajout de protoxyde d'azote. Cet effet pourrait être dû à la diminution de l'effet supprimeur des agents anesthésiques par inhalation sur l'EEG avec l'utilisation du NO et les propriétés neuro-stimulantes du NO. Le NO augmente les vitesses du flux sanguin cérébral ainsi que la consommation cérébrale d'oxygène.
2. Age : Il est difficile de titrer les agents anesthésiques chez les nourrissons de moins de 6 mois à l'aide du BIS ; cela pourrait être dû à une différence d'EEG dans cette population par rapport aux enfants plus âgés, car la maturation du cerveau et la formation de synapses se produisent pendant cette période. En 2001, Bannister et al. ont constaté qu'il n'y avait pas de différences significatives entre la pratique standard et la technique du BIS en ce qui concerne l'utilisation d'anesthésiques ou les mesures de récupération chez les enfants âgés de 6 mois à 3 ans.
3. Hypothermie : Doi et al. ont étudié 12 patients en hypothermie lors d'une intervention chirurgicale utilisant une pompe de circulation extracorporelle (CEC) qui est une technique dans laquelle une machine prend temporairement en charge la fonction du cœur et des poumons pendant la chirurgie, maintenant la circulation du sang et la teneur en oxygène du corps du patient. Une grande variation des valeurs BIS a été remarquée lors de la diminution de la température corporelle. Le BIS diminue de 1,12 unité pour chaque degré Celsius de réduction de la température corporelle. La réduction de la température entraîne une diminution du taux métabolique cérébral de l'oxygène qui se reflète sur l'EEG par des périodes isoélectriques. Le début de la circulation extracorporelle produit une dépression EEG transitoire probablement due à la perfusion du cerveau d'une solution

cristalloïde d'amorçage. Un ralentissement de l'EEG pouvant persister pendant la période post-circulation extracorporelle est observé lors d'une diminution des débits de circulation extracorporelle avec la libération du clamp aortique. La diminution des débits de CEC demandée par le chirurgien lors de la libération du clamp aortique est souvent corrélée au ralentissement de l'EEG qui peut persister dans la période post-CEC.

4. Déficience neurologique : La déficience neurologique altère la capacité du BIS à surveiller la profondeur de la conscience; ce n'est pas un outil fiable pour évaluer le niveau de conscience de cette population de patients. En général, les valeurs BIS sont plus faibles chez les patients atteints de troubles neurologiques. Les valeurs BIS reflètent l'activité de la structure corticale du cerveau mais ne reflètent pas l'activité des structures sous-corticales telles que la moelle épinière.
5. Interférence avec les dispositifs médicaux : les interférences provenant des dispositifs médicaux provoquent des artefacts et altèrent la capacité du moniteur BIS à évaluer avec précision les changements de profondeur de l'anesthésie. Chan et al. ont constaté que le SQI diminue lors de l'utilisation de la cautérisation électrochirurgicale.

De plus, les scientifiques ont exprimé des avis très controversés sur l'utilité de l'indice bispectral pour la prévention de conscience peropératoire lors d'une anesthésie générale. Un grand nombre d'études et d'essais ont été effectués, parmi eux les plus connus tels que les essais B-aware, B-unaware et BAG-RECALL [6]. Leurs conclusions convergent toutes vers le fait que, comparé à la surveillance des signes cliniques, le BIS a réduit le risque de conscience peropératoire, mais face au protocole "end-tidal anesthetic gas" (ETAG) qui se base sur la concentration d'anesthésique expiré dans les poumons en supposant qu'il est en équilibre avec la concentration cérébrale, le BIS ne donne aucune amélioration.

1.6 Etat de l'art

Depuis la commercialisation du BIS en 1994 et sa validation en 1994 par la US Food and Drug Administration (FDA), un grand nombre de scientifiques se sont penchés sur la question et ont essayé à leur tour de trouver un modèle ou algorithme qui, à partir des signaux EEG, permet d'émuler le BIS ou même de le contrôler. L'intelligence artificielle et les outils de l'apprentissage machine ont été énormément utilisés pour l'analyse des données EEG ainsi que pour déterminer la valeur BIS ou sa classification dans un intervalle. Des techniques plus poussées et des tentatives de modélisation mathématiques ont été utilisées afin d'automatiser et de contrôler cet indice.

1.6.1 Algorithmes d'apprentissage courants

1.6.1.1 Partitionnement (Clustering)

L'analyse de clustering est une forme d'analyse exploratoire des données dans laquelle les observations sont divisées en différents groupes partageant des caractéristiques communes qui correspondent le plus souvent à des critères de proximité définis en introduisant des mesures et des classes de distance entre objets. Le but de l'analyse de cluster (également appelée classification) est de construire des groupes (ou classes ou clusters) tout en assurant la propriété suivante : au sein d'un groupe, les observations doivent être aussi similaires que possible, tandis que les observations appartenant à des groupes différents doivent être aussi différentes que possible.

1.6.1.2 Machines à vecteurs de support (Support Vector Machine SVM)

Les SVM sont des algorithmes dont le but est de trouver une ligne ou frontière qui sépare les données en classes de manière optimale. Les SVM recherchent la plus grande marge entre les différents groupes de données et la frontière qui les sépare soit maximale. Les « vecteurs de support » sont les données les plus proches de la frontière. Lorsque le problème n'est pas linéaire (ce qui est souvent le cas), les SVM utilisent la méthode du « noyau » en projetant les données sur un espace vectoriel de plus grande dimension afin de pouvoir les séparer.

1.6.1.3 Arbre de décision (Decision Tree)

Il s'agit d'un classificateur arborescent, où les nœuds internes représentent les caractéristiques d'un ensemble de données, les branches représentent les règles de décision et chaque nœud feuille représente le résultat. Dans un arbre de décision, il y a deux nœuds, qui sont le nœud de décision et le nœud feuille. Les nœuds de décision sont utilisés pour prendre n'importe quelle décision et ont plusieurs branches, tandis que les nœuds feuilles sont le résultat de ces décisions et ne contiennent pas d'autres branches. Les décisions ou le test sont effectués sur la base des caractéristiques de l'ensemble de données.[7]

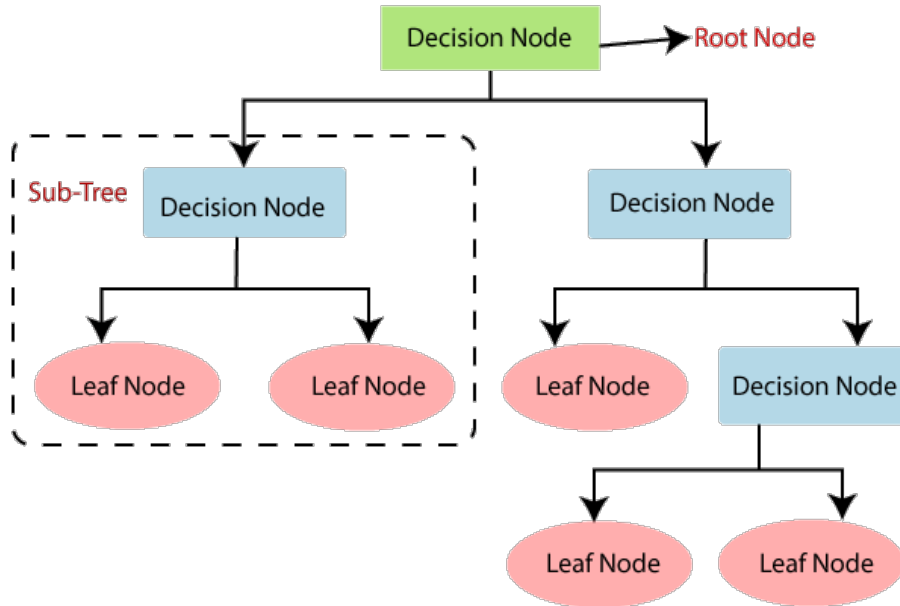


Figure 1.4 – Structure d'un arbre de décision [8]

1.6.2 Système d'inférence Neuro-Adaptative (Adaptive neuro-fuzzy inference system ANFIS)

C'est un modèle d'identification des systèmes linéaires ou non linéaires qui dépend du réseau neuronal (NN) et la logique floue (fuzzy logic FL) qui sont fondamentaux pour créer le modèle. L'objectif de cette méthode est d'intégrer les avantages spécifications des deux méthodes (FL et NN) où : La logique floue : usurpation d'identité des connaissances antérieures dans un groupe de contraintes pour minimiser le domaine de recherche d'optimisation, elle étend la logique booléenne classique avec des valeurs de vérités partielles. Elle consiste à tenir compte de divers facteurs numériques pour aboutir à une décision qu'on souhaite acceptable. Réseau de neurones : Adaptation de la rétropropagation pour la structure du réseau pour automatiser le réglage de la logique floue (FL).

ANFIS construit une cartographie entrée-sortie sur la base des deux connaissances humaines (sous la forme des règles floues if-then) et des paires de données d'entrée-sortie simulées. Il sert de base pour la construction de l'ensemble des règles floues si-alors avec fonctions d'appartenance appropriées pour générer les pairs d'entrées sorties[9].

Les paramètres associés aux fonctions d'appartenances sont ouvertes au changement et ajustable par le processus d'apprentissage, le calcul de ces paramètres (ou de leur ajustement) est facilité par un vecteur de gradient (règle d'apprentissage hybride, qui combine la technique de descente de gradient et l'estimateur des moindres carrés (MSE)), qui fournit dans quelle mesure l'ANFIS modélise les données de sortie d'entrée compte tenu de l'ensemble de paramètres. Une fois que le vecteur de gradient est obtenu, la rétropropagation ou l'algorithme d'apprentissage

hybride peuvent être appliqués afin d'ajuster les paramètres. La structure du modèle ANFIS se compose de cinq couches ayant chacune un rôle spécifique.

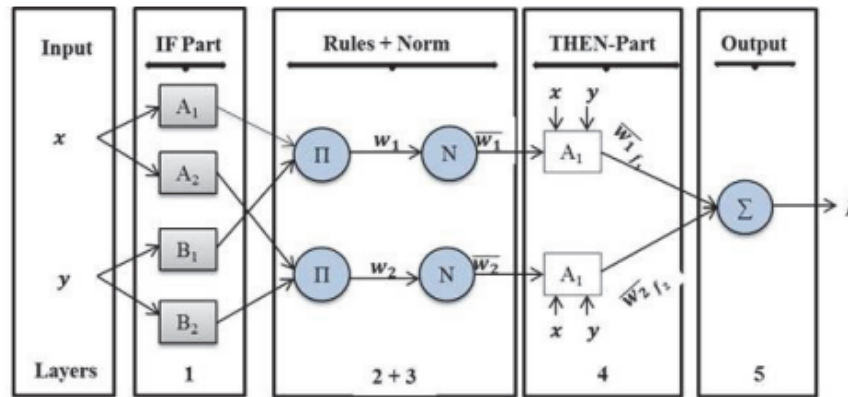


Figure 1.5 – Architecture ANFIS [9]

La première couche se charge de la fuzzification des entrées, c'est-à-dire l'estimation des fonctions d'appartenance. Les valeurs de ces dernières sont ensuite assemblées dans la seconde couche où elles sont multipliées pour créer la partie "if" des règles. Les sorties de cette couche sont ensuite normalisées via la troisième couche pour ensuite passer à l'étape de l'apprentissage à la quatrième couche (et à la partie "then" des règles) ou les paramètres sont évalués puis utilisés dans la cinquième couche pour calculer la sortie finale.[10]

1.6.3 Le modèle pharmacocinétique/pharmacodynamique (PK/PD)

C'est un modèle mathématique composé de deux systèmes (PK et PD) qui, à partir de la dose d'anesthésiant, permet de prédire l'indice bispectral et même d'appliquer différentes méthodes de contrôle pour l'automatiser. Tout d'abord, nous considérons l'approche de modélisation de l'agent anesthésiant et la façon dont l'agent anesthésiant administré se distribue dans le corps. Cette étape conduit à un modèle pharmacocinétique (PK) qui peut être utilisé pour prédire la concentration plasmatique du médicament dans le sang. La deuxième étape est l'expression mathématique liée à la concentration à l'effet du médicament lui-même. Cette expression est appelée modèle pharmacodynamique (PD)[11].

1.6.3.1 Pharmacocinétique

La pharmacocinétique est l'étude de l'absorption, de la distribution, du métabolisme et de l'élimination des médicaments par l'organisme, un modèle basé sur une approche compartimentale est utilisé. Selon cette approche, le corps est supposé divisé en plusieurs compartiments. Dans chaque compartiment la concentration en médicament est homogène et il y a des échanges

entre compartiments. Un modèle à trois compartiments est utilisé, dans lequel le compartiment principal représente le sang intravasculaire (sang dans les artères et les veines) et les organes fortement irrigués (comme le cœur, le cerveau, le foie et les reins). Les deux autres compartiments représentent les muscles, la graisse et d'autres organes ou tissus.




Figure 1.6 – Modèle PK [12]

Le modèle pharmacocinétique est un terme mathématique relatif à la concentration plasmatique du médicament $C_p(s)$ par rapport à la dose administrée $u(s)$.

$$PK(s) = \frac{C_p(s)}{u(s)} \quad (1.3)$$

La PK peut être exprimée comme une évolution dans le temps de la concentration d'un médicament donné dans le plasma et d'autres tissus du corps humain. Tout au long de la phase d'absorption suivant l'administration d'un bolus intraveineux, l'anesthésique (propofol) se mélange rapidement dans le pool sanguin central, entraînant un pic de concentration plasmatique. Il s'écoule un délai entre l'injection effective de l'anesthésique (propofol) et son mélange dans le pool sanguin. La circulation systémique distribue ensuite l'anesthésique à une variété de tissus dans le corps. L'évolution dans le temps de la concentration pour la plupart des médicaments, dans le plasma sanguin après l'administration et l'absorption intraveineuses peut être ajustée pour ressembler à une fonction en décomposition, avec deux modes distincts correspondant respectivement à la phase de distribution et d'élimination.

La quantité totale d'anesthésique délivrée dans le compartiment un (C_1) est éliminée selon la constante de vitesse k_{10} . L'anesthésique est distribué dans les deux autres compartiments (C_2, C_3) à raison de k_{12} et k_{13} . La concentration de (C_1) diminue rapidement tandis que les concentrations (C_2, C_3) augmentent. Une fois que les concentrations dans le compartiment 1 et dans l'un des compartiments périphériques (C_2, C_3) atteignent et atteignent l'équilibre, le ralentissement du processus de distribution et l'anesthésique stocké dans le compartiment périphérique retournent dans le compartiment central au taux de k_{21} ou k_{31} . Parce que le sang du compartiment un agit comme un transporteur pour l'anesthésique, c'est-à-dire qu'il n'y a pas d'échange direct entre les

deux compartiments périphériques. Autrement dit, seul l'anesthésique présent dans le compartiment un peut être éliminé.

Le modèle est représenté mathématiquement par les équations d'état suivantes :

$$\dot{C}_1(t) = (-k_{10} - k_{12} - k_{13})C_1(t) + k_{21}C_2(t) + k_{31}C_3(t) + \frac{u(t)}{V_1} \quad (1.4)$$

$$\dot{C}_2(t) = k_{12}C_1(t) - k_{21}C_2(t) \quad (1.5)$$

$$\dot{C}_3(t) = k_{13}C_1(t) - k_{31}C_3(t) \quad (1.6)$$

$$C_p(t) = C_1(t) \quad (1.7)$$

1.6.3.2 Pharmacodynamique

La pharmacodynamie (PD) est l'étude des effets des médicaments et de la relation entre la concentration $C_p(s)$ et l'effet des médicaments $E(s)$. La fonction du modèle PD est d'exprimer mathématiquement l'effet observé d'un médicament.

$$PD(s) = \frac{E(s)}{C_p(s)} \quad (1.8)$$

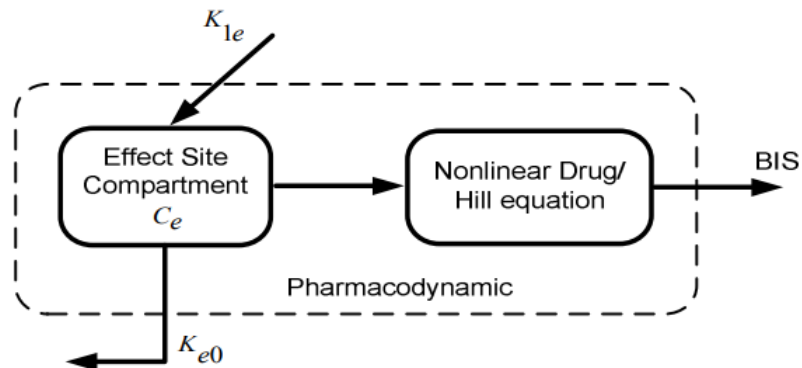


Figure 1.7 – Modèle PD [12]

Il est caractérisée par un filtre passe-bas lié à la concentration du compartiment central C_p dans le sang et est représenté par l'équation d'état

$$\dot{C}_e(t) = k_{e0}(C_p - C_e) \quad (1.9)$$

Où C_e désigne la concentration au site d'effet et C_p désigne la concentration plasmatique. La variable BIS liée à la concentration de l'effet médicamenteux par la relation empirique statique non linéaire, appelée Sigmoid Hill Curve :

$$E(t) = E_0 - E_{max} \frac{C_e^\gamma}{EC_{50}^\gamma + C_e^\gamma} \quad (1.10)$$

où E est l'effet mesuré, E_0 représente la valeur de base (état conscient sans propofol), qui est généralement fixée à 100; E_{max} désigne l'effet maximal obtenu par la perfusion de médicament; EC_{50} est la concentration du médicament à mi-effet maximal et indique la sensibilité du patient au médicament; et γ détermine la pente de la non-linéarité statique. Le modèle PK/PD complet représenté dans la figure 1.8 est utilisé avec des données de patients lors d'anesthésie et peut être soumis à différents types de contrôleurs afin de réguler les valeurs de l'indice bispectral

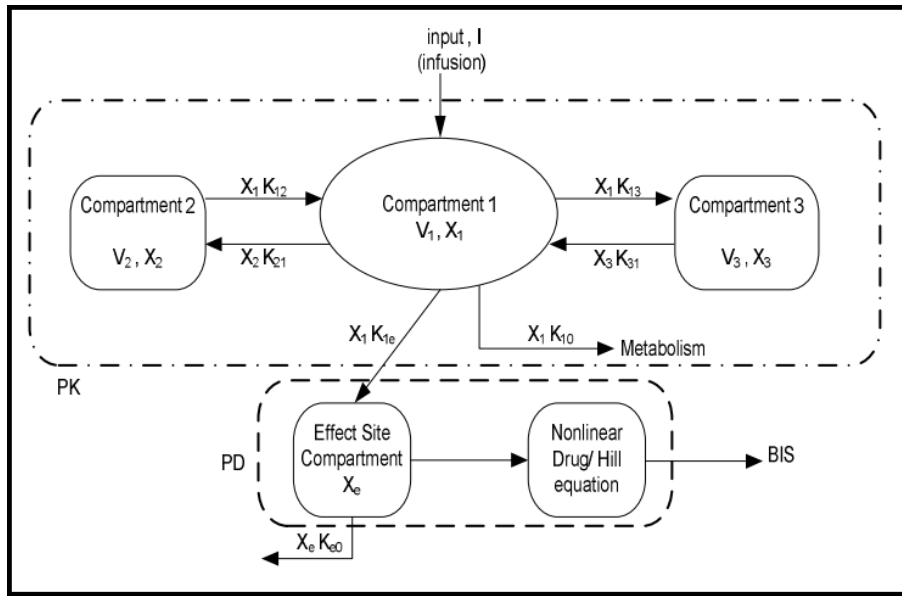


Figure 1.8 – Modèle PK/PD [11]

1.7 Conclusion

Dans ce chapitre, nous avons exposé les caractéristiques de l'indice bispectral et sa méthode de calcul. Malgré ses limites, il est évident que celui-ci joue un rôle important dans le monde de l'anesthésie. Les travaux effectués et les méthodes utilisées ont nourri notre intérêt et nous ont poussés à essayer à notre tour de proposer une approche pour prédire et déterminer la profondeur de l'anesthésie d'un patient.

Chapitre 2

Ensemble de données (Dataset)

2.1 Introduction

Un bon modèle d'apprentissage n'est pas suffisant pour assurer de bons résultats, ces derniers dépendent directement des données disponibles. Les données doivent être fiables et de bonne qualité. De plus, une bonne connaissance est primordiale pour appliquer les traitements adéquats afin de tirer le maximum d'informations utiles qui seront entrées dans le modèle d'apprentissage. Cependant, trouver des données qui fournissent ces critères n'est pas chose facile, surtout dans le domaine médical. Dans ce chapitre, nous commencerons par mettre en évidence les difficultés face auxquelles on peut se confronter lorsqu'on veut utiliser des méthodes d'apprentissage sur des données médicales. Puis nous présenterons l'ensemble de données choisi pour notre travail ainsi que son acquisition et le traitement effectué sur celui-ci.

2.2 Difficultés

L'obtention d'un bon ensemble de données est un réel challenge dans le domaine médical. En effet, le coût élevé des expériences et le temps nécessaire à leur exécution est un obstacle considérable. Cela est encore plus accentué pour des données de type EEG où la présence d'un simple bruit ou la plus insignifiante erreur dans le système de montage (mauvais placement ou non adhérence des capteurs sur le crâne) peut rendre les données inutilisables. Une autre complication est l'accès très restreint aux données. Dans la majorité des cas, lorsque des expériences sont menées dans les hôpitaux, les bases de données restent privées et confidentielles (considérées propriété de l'établissement). Et lorsque ce n'est pas le cas, l'utilisation des données nécessite l'accord des patients.

2.3 Présentation du dataset

Les données ont été extraites de VitalDB, un référentiel ouvert de données sur les signes vitaux peropératoires (<http://vitaldb.net/data-bank>) [13]. La collecte et la diffusion publique de l'ensemble de données VitalDB ont été approuvées par le comité d'examen institutionnel de l'hôpital universitaire national de Séoul (H-1408-101-605), et la construction du référentiel de données a également été enregistrée sur le site d'enregistrement des essais cliniques accessible au public (ClinicalTrial.gov, NCT02914444). Cette base de données contient des données issues de différentes machines utilisées durant les opérations chirurgicales : des moniteurs d'anesthésie (BIS Vista), des pompes à perfusions (Orchestra), des moniteurs sanguins (Vigileo)...etc.

2.4 Acquisition et enregistrement des données

Les données ont été collectées dans 10 salles d'opération de l'hôpital universitaire national de Séoul de juin 2016 à août 2017, à l'aide du logiciel d'enregistrement Vital Recorder.

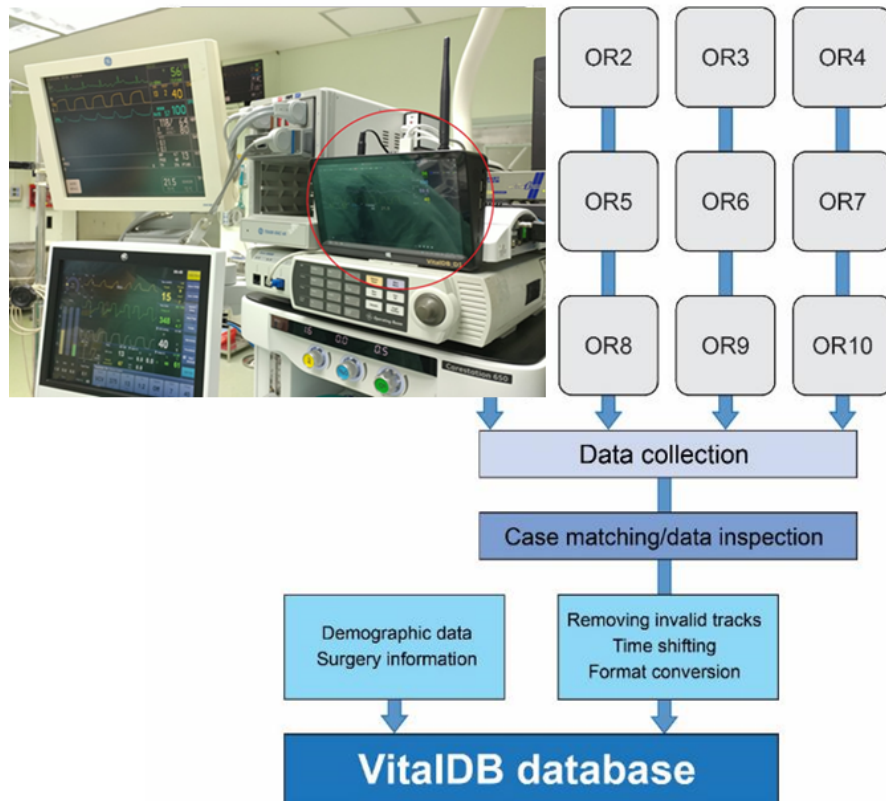


Figure 2.1 – Schéma d'obtention des données de VitalDB [13]

La surveillance de l'état de la connexion et de la collecte de l'équipement pendant que les données sont collectées par se fait à distance par le Vital Recorder. Pour ce faire, il suffit de télécharger les données collectées par le Vital Recorder sur le serveur, puis de les télécharger sur le navigateur web de l'utilisateur. Cette opération requiert d'avoir un ordinateur avec Vital Recorder connecté à internet et d'un navigateur web. L'organigramme des données est le suivant :




Figure 2.2 – Organigramme de données

Lorsque le web monitoring est fait correctement, un écran apparaît montrant les biosignaux pendant que l'enregistrement se poursuit

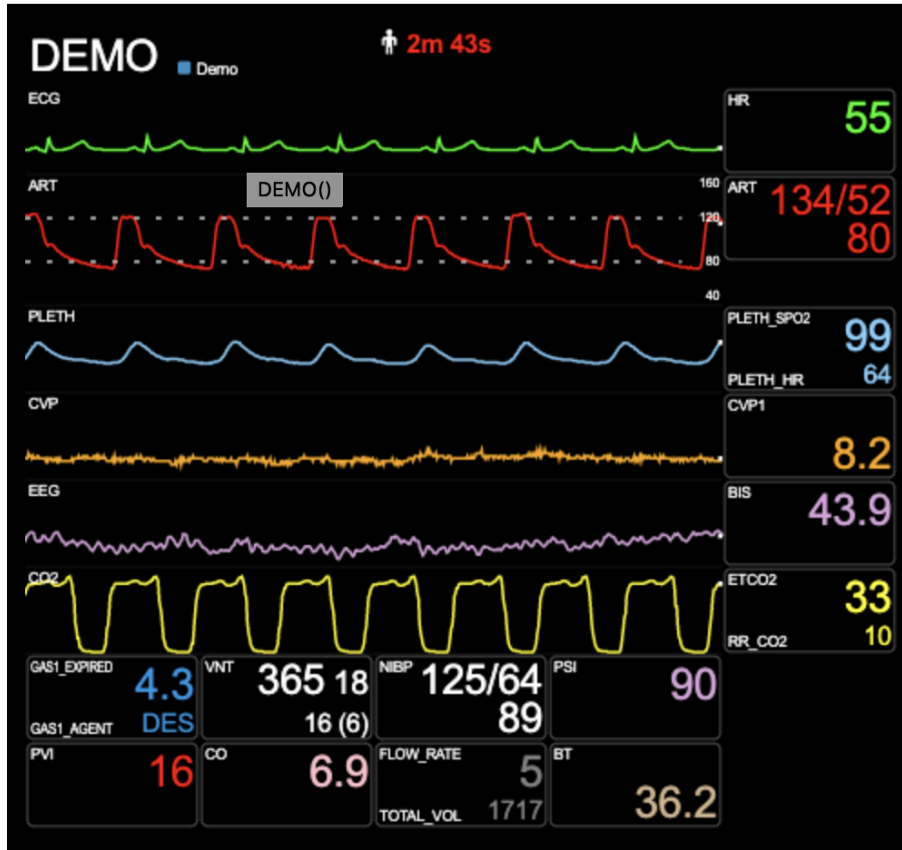


Figure 2.3 – Schéma d’obtention des données de VitalDB [13]

2.5 Sélection des données

Pour la première partie du travail, nous avons sélectionné l’ensemble des données dont l’origine est le moniteur BIS, ce qui se résume à un groupe de paramètres présentés dans la section 1.4.5 qui ont une influence connue sur les valeurs de l’indice bispectral.

Paramètre	Description	Unité
BIS/BIS	Valeur de l’indice bispectral	Sans unité
BIS/EMG	Puissance de l’électromyographie	dB
BIS/SEF	Spectral Edge Frequency	Hz
BIS/SQI	Signal Quality Index	%
BIS/TOTPOW	Energie Totale	dB
BIS/SR	Suppression Ratio	%

Table 2.1 – Description des données utilisées dans la première version du dataset

Dans le but d'enrichir notre ensemble de données afin d'entraîner un modèle d'apprentissage profond, nous avons ajouté à nos paramètres des informations cliniques sur le patient (âge, sexe, taille, poids) ainsi que leur historique d'infusion des deux agents anesthésiques propofol et rémifentanil pendant leur opération chirurgicale où l'anesthésie a été faite par intraveineuse.

Paramètre	Unité
Age	Année
Sexe	M/F
Taille	cm
Poids	Kg
Concentration de propofol (Orchestra/PPF20 _C T)	mcg/mL
Volume de propofol (Orchestra/PPF20 _V OL)	mL
Concentration de rémifentanil (Orchestra/RFTN20 _C T)	mcg/mL
Volume de rémifentanil (Orchestra/RFTN20 _V OL)	mL

Table 2.2 – Paramètres ajoutés pour former la seconde version du dataset

2.6 Téléchargement des données

Après avoir choisi les données que nous allons utiliser, nous passons au téléchargement. Pour cela, VitalDB a mis à notre disposition une bibliothèque python qui appelle l'API du web monitoring pour avoir accès aux données.

Exemple de code qui télécharge la forme d'onde artérielle d'un patient de VitalDB et l'enregistre en fichier png :

```
import matplotlib.pyplot as plt
from vitaldb import load_cases

cases = load_cases('SNUADC/ART,Solar8000/ART_SBP', interval=1/100, maxcases=1)
for caseid, case in cases.items():
    plt.figure(figsize=(20, 5))
    plt.plot(case[:, 0])
    plt.savefig('{} .png'.format(caseid))
```

2.7 Traitement des données

Avant d'introduire des données dans un modèle, celles-ci nécessitent un traitement afin d'assurer une meilleure performance des modèles. Pour cela, il faut avoir une bonne connaissance des variables ainsi que leur signification. Le premier traitement effectué sur notre dataset a été basé sur l'indice de qualité de signal. En effet, pour s'assurer de la qualité de l'information, nous

n'avons gardé que les cas où l'indice $SQI \geq 80$. En faisant cela, nous diminuons le risque de travailler sur des données erronées. Comme nous avons une variable catégorielle (sexe du patient M ou F), nous en créons de nouvelles pour la représenter de manière numérique. La première prendra la valeur 0 si le patient est une femme et 1 si le patient est un homme, et la seconde fera l'inverse. Car les variables numériques sont mieux prises en charge dans les modèles d'apprentissage. Suite à cela, un partitionnement des données a été fait pour l'application de la méthode de validation croisée (expliquée dans la section 3.3.1). L'ensemble des données est divisé en trois sous-ensembles :

- Ensemble d'entraînement (training set) : contient les données sur lesquelles le modèle doit s'entraîner. Cet ensemble regroupe généralement 70% des données.
- Ensemble de validation (validation set) : le modèle ne s'entraînera pas sur cet ensemble. C'est plutôt l'ensemble où nous devons peaufiner les hyper-paramètres du modèle dans le but d'améliorer sa précision. Cet ensemble contient en général 15% des données.
- Ensemble de test (test set) : afin d'avoir une évaluation qui se rapproche du cas réel, cet ensemble de données ne doit pas être touché lors de la phase d'entraînement. Il contient en règle générale 15% des données.

Les variables numériques passent par une normalisation, les valeurs passent alors d'un intervalle quelconque à des valeurs entre 0 et 1. La normalisation se fait en utilisant la moyenne et l'écart-type de l'ensemble d'entraînement selon l'équation :

$$X = \frac{X - u}{\sigma} \quad (2.1)$$

Avec u la moyenne de la variable sur l'ensemble d'entraînement :

$$u = \frac{1}{n} \sum_{i=1}^n x_i \quad (2.2)$$

et σ l'écart-type de la variable sur l'ensemble d'entraînement :

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - u)^2} \quad (2.3)$$

La méthode du "smoothing" est également appliquée sur les valeurs du BIS. Cette méthode statistique consiste à créer une fonction d'approximation qui tente de capturer les modèles importants de la variable [14]. Il existe plusieurs algorithmes appliquant cette approximation et le but principal de chacune d'entre eux est l'élimination du bruit sur les données. Le dernier traitement se fait sur les données temporelles, à partir du volume infusé de chaque agent anesthésiant et de la concentration de ce dernier, l'historique d'infusion de chaque médicament a pu être calculé, puis normalisé.

2.8 Conclusion

Dans ce chapitre, nous avons attiré l'attention sur le problème réel de la recherche de bons ensembles de données. Nous avons ensuite présenté l'ensemble sur lequel notre travail a été effectué et les différents traitements par lesquels celui-ci est passé afin de le préparer à être l'entrée de notre modèle de prédiction. Dans le chapitre suivant, nous exposerons les différents modèles et méthodologies utilisés et appliqués sur les données afin de répondre à la problématique de prédiction de l'indice bispectral.

Chapitre 3

Méthodologies

3.1 Introduction

Dans les chapitres précédents, nous avons présenté l'indice bispectral ainsi que le traitement sur notre ensemble de données. L'avantage du choix des différents modèles est de pouvoir étudier les avantages de chacun ainsi que la possibilité d'en évaluer les performances afin de les comparer. Dans ce chapitre, nous donnerons des notions sur les différents types d'apprentissage et des méthodes utilisées sur nos données et nous présenterons les modèles proposés afin de prédire les valeurs de l'indice bispectral.

3.2 Apprentissage machine

3.2.1 Rappel sur la méthode du gradient

L'algorithme du gradient est un algorithme d'optimisation dont l'objectif est d'ajuster de manière adéquate des paramètres en vue de minimiser une fonction coût choisie J . C'est l'algorithme d'optimisation le plus répandu. Il ne possède qu'un seul paramètre : le taux d'apprentissage (learning rate) dont le rôle est d'indiquer la vitesse à laquelle les coefficients sont ajustés. L'ajustement des paramètres se fait selon l'équation suivante :

$$\theta = \theta - \alpha \frac{\partial J}{\partial \theta} \quad (3.1)$$

3.2.2 Le renforcement de gradient (Gradient Boosting)

Le renforcement de gradient est une technique d'apprentissage automatique pour la régression, la classification et d'autres tâches, qui produit un modèle de prédiction sous la forme d'un ensemble de modèles de prédiction faibles, généralement des arbres de décision. Lorsqu'un arbre de décision est l'apprenant faible, l'algorithme qui en résulte est appelé arbres à gradient renforcé. Il construit le modèle par étapes et les généralise en permettant l'optimisation d'une fonction de perte différentiable arbitraire.

[15] Fonctionnement du Gradient Boosting : Le gradient boosting implique trois éléments :

- Une fonction objectif à optimiser.
- Un modèle d'apprentissage faible pour faire des prédictions.
- Un modèle additif pour ajouter des modèles d'apprentissage faibles afin de minimiser la fonction objectif.

1. Fonction objectif :

La fonction objectif utilisée dépend du type de problème à résoudre. La fonction coût ou fonction d'erreur mesure l'écart entre la prédiction \hat{y}_i et la sortie réelle y_i . La fonction coût est une méthode d'évaluation de « dans quelle mesure l'algorithme modélise l'exemple ».

Si la prédiction est loin de la sortie souhaitée, la fonction coût produira un nombre plus élevé. A l'inverse, s'il est assez bon, le nombre sera inférieur. La fonction objectif est la moyenne de la fonction coût de l'ensemble de l'apprentissage.

Elle doit être différentiable, mais de nombreuses fonctions objectif standard sont prises en charge. Par exemple, la régression peut utiliser une erreur quadratique et la classification peut utiliser une perte logarithmique.

2. Modèle d'apprentissage faible :

Les arbres de décision sont utilisés comme apprenant faible dans le renforcement du gradient. Plus précisément, des arbres de régression sont utilisés pour générer des valeurs réelles pour les divisions et dont les sorties peuvent être additionnées, permettant d'ajouter les sorties de modèles ultérieures et de « corriger » les erreurs dans les prédictions. Les arbres sont construits de manière à choisir les meilleurs points de division pour minimiser la perte.

3. Modèle additif :

Les arbres sont ajoutés un par un et les arbres existants dans le modèle ne sont pas modifiés. Une procédure de descente de gradient est utilisée pour minimiser la perte lors de l'ajout d'arbres.

Traditionnellement, la descente de gradient est utilisée pour minimiser un ensemble de paramètres, tels que les coefficients dans une équation de régression ou les poids dans un réseau de neurones. Après avoir calculé l'erreur ou la perte, les poids sont mis à jour pour minimiser cette erreur.

Au lieu de paramètres, nous avons des sous-modèles d'apprenants faibles ou plus précisément des arbres de décision. Après avoir calculé la fonction objectif, pour effectuer la procédure de descente de gradient, nous devons ajouter un arbre au modèle qui réduit la perte (c'est-à-dire suivre le gradient). Nous faisons cela en paramétrant l'arbre, puis modifions les paramètres de l'arbre et avançons dans le bon sens en (réduction de l'erreur).

3.2.2.1 Principe et Algorithme

Le renforcement du gradient combine les « apprenants » faibles en un seul apprenant fort de manière itérative [16]. Dans le cadre de la régression des moindres carrés, où l'objectif est d'apprendre à un modèle F à prédire les valeurs de la forme $F(x) = Y$ en minimisant l'erreur quadratique moyenne :

$$\frac{1}{n} \sum_i (\hat{y}_i - y_i)^2 \quad (3.2)$$

où i indexe sur un ensemble d'apprentissage de taille n des valeurs réelles de la variable de sortie y :

— y_i =la valeur observée de la sortie

- \hat{y}_i = la valeur prédite de la sortie
- n = nombre d'échantillons de données.

Pour algorithme de renforcement de gradient avec M étapes. A chaque étape m de nous avons un modèle imparfait F_m . Afin de l'améliorer, notre algorithme devrait ajouter un nouvel estimateur h_m . Ainsi :

$$F_{m+1}(x) = F_x + h_m(x) \quad (3.3)$$

ou équivalent :

$$h_m = F_{m+1}(x) - F_m(x) \quad (3.4)$$

Par conséquent, le renforcement du gradient adaptera h au résidu $y - F_m(x)$. Chaque $F_m + 1$ tente de corriger les erreurs de son prédécesseur F_m . Les résidus h_m pour un modèle donné sont les gradients négatifs de la fonction objectif d'erreur quadratique moyenne (MSE) (par rapport à $F(x)$) :

$$L_{mse} = \frac{1}{2}(y - F(x))^2 \quad (3.5)$$

$$h_m(x) = -\frac{\partial L_{mse}}{\partial F} = y - F(x) \quad (3.6)$$

Ainsi, le gradient boosting pourrait être spécialisé dans un algorithme de descente de gradient, et sa généralisation implique de "brancher" une fonction objectif différente et son gradient.

Algorithm 1 Algorithme du renforcement de gradient

Input : training set $(x_i, y_i)_{i=1}^n$, a differentiable loss function $L(y, F(x))$, number of iteration M .

1: Initialize model with a constant value. $\triangleright F_0 = \arg_{\gamma} \min \sum_{i=1}^n L(y_i, \gamma)$

2: **for** $m=1$ to M **do**

\perp :

 1. Compute so-called pseudo-residuals :

$$\tau_{im} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x)=F_{m-1}(x)} \quad \text{for } i=1, \dots, n. \quad (3.7)$$

 2. Fit a base learner (or weak learner, e.g. tree) $h_m(x)$ to pseudo-residuals, i.e. train it using the training set

 3. Compute multiplier γ_m by solving the following one-dimensional optimization problem :

$$(\gamma_m = \arg_{\gamma} \min \sum_{i=1}^n L(y_i, F_{m-1}(x_i) + \gamma h_m(x_i))) \quad (3.8)$$

 4. Update the model

$$F_m(x) = F_{m-1}(x) + \gamma_m h_m(x). \quad (3.9)$$

3: **Output** $F_M(x)$

3.2.3 Modèle CatBoost

CatBoost est un puissant algorithme basé sur le gradient boosting d'arbres de décision, ce qui le différencie des autres méthodes est qu'il développe des "Oblivious decision trees" [17], c'est à dire des arbre de décision symétriques où toutes les feuilles ont le même niveau et où la même règle de division est appliquée à tous les nœuds intermédiaires dans le même niveau de l'arbre, ce qui permet de réduire considérablement le temps de prédiction.

3.2.4 Modèle LightGBM

LightGBM est un algorithme de renforcement de gradient basé sur des arbres de décision pour augmenter l'efficacité du modèle et réduire l'utilisation de la mémoire.

Il utilise deux nouvelles techniques : l'échantillonnage unilatéral basé sur le gradient (Gradient-based One Side Sampling GOSS) et le regroupement de fonctionnalités exclusives (Exclusive Feature Bundling EFB). Ces deux dernières décrites ci-dessous forment les caractéristiques de l'algorithme LightGBM. Elles se combinent pour faire fonctionner le modèle efficacement et lui donner une longueur d'avance sur les autres algorithmes de gradient boosting.[18]

Avec GOSS, nous excluons une proportion significative d'instances de données avec de petits gradients et n'utilisons que le reste pour estimer le gain d'informations. Nous prouvons que,

puisque les instances de données avec des gradients plus importants jouent un rôle plus important dans le calcul du gain d'information, GOSS peut obtenir une estimation assez précise du gain d'information avec une taille de données beaucoup plus petite.

EFB est une approche permettant de regrouper des fonctionnalités rares mutuellement exclusives (c'est-à-dire qu'elles prennent rarement des valeurs différentes de zéro simultanément) afin de diminuer le nombre de fonctionnalités sans pour autant nuire à la précision.[19]

Avec ces deux techniques, LightGBM réduit considérablement le temps d'exécution tout en donnant de bons résultats.

3.2.5 Modèle XGBoost

XGBoost ou Extreme Gradient Boosting est un algorithme d'apprentissage machine d'ensemble basé sur un arbre de décision qui utilise un cadre de renforcement de gradient. C'est un modèle largement utilisé de par ses performances et la vitesse d'exécution qu'il offre, et ce, grâce à son optimisation des systèmes et ses améliorations algorithmiques.[20]

Ce modèle présente plusieurs avantages ; son processus de construction d'arbres en utilisant une implémentation parallélisée et son élagage d'arbres dans le sens inverse assure de meilleures performances de calcul et sa gestion des valeurs manquantes et la régularisation permet d'éviter le surajustement ou un biais sur les données.




Figure 3.1 – Comparaison de développement d'arbre de décision pour XGBoost et LightGBM [21]

3.2.6 Modèle RandomForest

La forêt aléatoire ou RandomForest est un algorithme d'apprentissage supervisé. La "forêt" qu'il construit est un ensemble d'arbres de décision, généralement formés avec la méthode "bagging". L'idée générale de cette méthode est qu'une combinaison de modèles d'apprentissage augmente le résultat global. [22] En d'autres termes, RandomForest construit plusieurs arbres de décision et les fusionne pour obtenir une prédiction plus précise et plus stable.

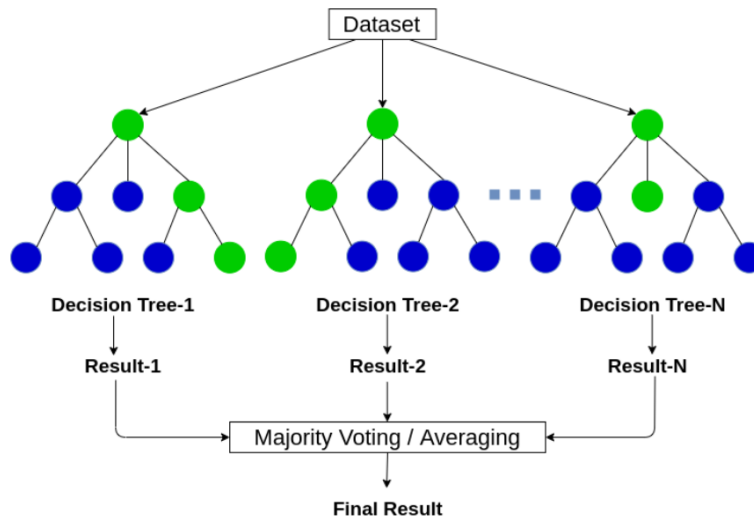


Figure 3.2 – Schéma de la forêt aléatoire [23]

RandomForrest ajoute un caractère aléatoire supplémentaire au modèle, tout en faisant croître les arbres. Au lieu de rechercher la caractéristique la plus importante lors de la division d'un nœud, elle recherche la meilleure caractéristique parmi un sous-ensemble aléatoire de caractéristiques. Il en résulte une grande diversité qui se traduit généralement par un meilleur modèle. [23]

3.3 L'empilement des modèles (Model Stacking)

L'empilement est le processus d'utilisation de différents modèles d'apprentissage automatique l'un après l'autre, où les prédictions de chaque modèle sont ajoutées pour créer une nouvelle fonction. L'empilement de modèles doit toujours être accompagné d'une validation croisée, afin de réduire le surajustement des modèles aux données d'apprentissage. [24]

3.3.1 Validation croisée

La validation croisée et plus précisément la méthode de validation croisée k-fold est très utilisée en apprentissage automatique de modèles, et ce pour évaluer les performances d'un modèle ou pour développer un empilement de modèles.




Figure 3.3 – Méthode de validation croisée K-fold [25]

Cette technique consiste à diviser l'ensemble de données en k groupes, et pour chacun d'eux appliquer les étapes suivantes [26] :

- Prendre le groupe comme ensemble de données de validation.
- Prendre les groupes restants comme ensemble de données d'entraînement.
- Entraîner le modèle sur l'ensemble de données d'entraînement puis appliquer le modèle entraîné à l'ensemble de données de validation.
- Évaluer les performances du modèle à l'aide de critères ou utiliser les prédictions du modèle pour l'empilement.

3.3.2 Processus d'empilement

L'empilement des modèles d'apprentissage automatique se fait par couches, et il peut y avoir un nombre arbitraire de couches, en fonction du nombre exact de modèles formés, ainsi que de la meilleure combinaison de ces modèles.

Nous plaçons des piles de modèles en couches, et généralement avec un objectif différent. Le principe de l'empilement est qu'en utilisant la méthode de validation croisée, chaque ensemble de données d'entraînement est à son tour divisé en deux ensemble : entraînement et test. Après application de la méthode, chaque données aura eu k prédictions test et une prédiction de validation. Ces données seront ajoutées aux ensembles d'entraînement et de validation respectivement et serviront d'entrées pour le modèle suivant.[24]

À la fin, nous obtenons un ensemble de données final, que nous introduisons dans un dernier modèle. Le dernier modèle est appelé "un méta-learner", et son objectif est de généraliser toutes les caractéristiques de chaque couche dans les prédictions finales.

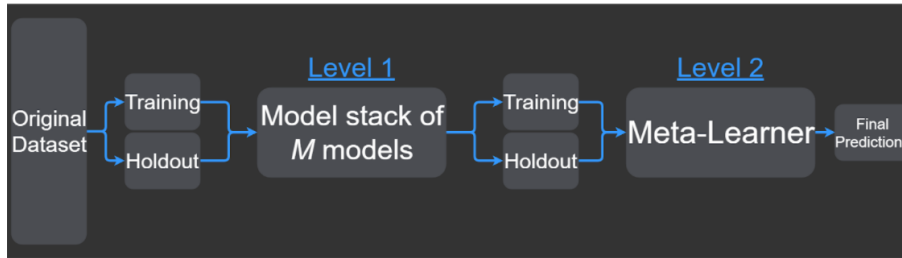


Figure 3.4 – Couches des piles de modèles [24]

3.4 Apprentissage profond

L'apprentissage profond (en anglais : Deep Learning) est un ensemble de méthodes d'apprentissage automatique qui modélisent les données en utilisant un haut niveau d'abstraction. Nous discuterons dans cette section des bases des modèles d'apprentissage profond pour avoir une intuition de leur fonctionnement.

L'apprentissage profond est un sous-domaine de l'apprentissage automatique qui concerne les algorithmes inspirés de la structure et de la fonction du cerveau. Il tire parti de l'apprentissage des hiérarchies de caractéristiques où les caractéristiques des niveaux supérieurs de la hiérarchie sont formées par la composition des caractéristiques de niveau inférieur. Son architecture est composée de plusieurs couches de traitement qui lui permettent d'apprendre des représentations de données avec plusieurs niveaux d'abstraction.

3.4.1 Réseaux de neurones artificiels

Les réseaux de neurones artificiels, ou simplement les réseaux de neurones (NN), sont un type de modèles d'apprentissage automatique inspirés des réseaux de neurones humains. La structure de NN est similaire à celle de notre cerveau, qui a des neurones et des connexions entre eux pour transmettre des impulsions électriques.

Chaque neurone est optimisé pour recevoir des informations d'autres neurones, traiter ces informations de manière unique et envoyer son résultat à d'autres cellules. En s'appuyant sur le comportement fonctionnel du neurone biologique, nous pouvons définir une unité de calcul que l'on appelle le neurone artificiel. Le neurone artificiel est l'unité de base de ce qu'on appelle les réseaux de neurones.

Mathématiquement, il peut être représenté comme une fonction qui prend un certain nombre d'entrées x_1, x_2, \dots, x_m , chacune de ces entrées a un poids correspondant w_1, w_2, \dots, w_m . La somme pondérée des entrées plus le terme de biais forment la partie linéaire de la transformation produisant z , suivie de la partie non linéaire produisant la sortie du neurone y , qui est l'application de la fonction d'activation. Le but du biais est de déplacer réellement votre fonction d'activation

vers la gauche et vers la droite quelles que soient les entrées pour mieux s'adapter aux données.

$$z = \sum_{i=1}^2 w_i x_i + b \quad (3.10)$$

$$y = f(z) \quad (3.11)$$

De nombreuses fonctions d'activation ont été proposées dans la littérature et seront discutées dans les prochains paragraphes. Notez que dans certains cas, la fonction d'activation peut être linéaire (par exemple, problèmes de régression).




Figure 3.5 – Schéma d'un neurone artificiel

Un neurone est l'unité de base d'un réseau de neurones, ce dernier est représenté comme une organisation en couches de neurones avec des connexions à d'autres neurones. La couche d'entrée est représentée par les données d'entrée, la couche de sortie est la dernière qui traite les données et renvoie les résultats de l'ensemble du modèle, tandis que toutes les couches intermédiaires sont appelées couches cachées. Ces couches cachées transforment les données d'une couche à une autre et envoient les informations traitées à la couche suivante. Ils sont ce qui rend le réseau profond. Cette caractéristique du réseau est ce qui a popularisé le terme « Deep Learning » qui est le domaine d'étude associé à tout ce qui touche aux ANN.




Figure 3.6 – Architecture d'un réseau de neurones [27]

3.4.2 Fonctions d'activation

Les fonctions d'activation sont un élément constitutif des réseaux de neurones, c'est la deuxième transformation de chaque neurone après la partie linéaire et c'est une fonction non linéaire afin d'aider le modèle à apprendre des motifs complexes. Dans cette section, nous présenterons les fonctions d'activation les plus communes.

3.4.2.1 Fonction sigmoïde

C'est l'une des fonctions d'activation non linéaires les plus utilisées. Il a été utilisé pour prédire la sortie basée sur la probabilité et a été appliqué avec succès dans des problèmes de classification binaire. Il est défini par :

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.12)$$

La fonction sigmoïde traduit l'entrée dans la plage $[-\infty, +\infty]$ vers l'intervalle $[0, 1]$. La fonction est monotone croissante et continûment dérivable. Pour les petites valeurs de x , il est plus proche de 0. Inversement, plus x est grand, plus il est proche de un.




Figure 3.7 – graphe de la fonction sigmoïde

3.4.2.2 Fonction tangente hyperbolique tanh

La fonction Tanh utilise un type similaire de non-linéarité en forme de S comme la fonction sigmoïde, mais au lieu de varier de 0 à 1, la sortie de tanh varie de -1 à 1. Elle est définie par l'équation suivante :

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.13)$$




Figure 3.8 – graphe de la fonction tanh

3.4.2.3 Fonction ReLU

La fonction d'activation ReLU (Unité linéaire rectifiée) effectue une opération de seuil sur chaque élément d'entrée où les valeurs inférieures à zéro sont mises à zéro et renvoie la sortie

d'identité dans le cas contraire.

$$f(x) = \max(0, x) \quad (3.14)$$

Le principal avantage de ReLU est que la puissance de calcul est plus rapide car il ne calcule pas les exposants et les divisions, ce qui en fait le neurone de choix pour de nombreuses tâches.




Figure 3.9 – graphe de la fonction ReLU

3.4.3 Réseaux de neurones à propagation avant

Les réseaux de neurones à propagation avant (en anglais : Feed-Forward Neural Network) sont au cœur des modèles d'apprentissage profonds. Le but d'un réseau feed-forward est d'approximer une fonction f . Il définit une application $y = f(x; \omega)$ et apprend la valeur des paramètres ω qui donnent la meilleure approximation de la fonction. Ils sont appelés feed-forward car les informations ne circulent que vers l'avant dans le réseau (pas de boucles), d'abord à travers les nœuds d'entrée, puis à travers les nœuds cachés (s'il y en a) et enfin à travers les nœuds de sortie. Le réseau est également appelé entièrement connecté car la sortie de chaque neurone d'une couche est envoyée en entrée de chaque neurone de la couche suivante, il existe donc une connexion directe entre tous les neurones appartenant aux couches suivantes.




Figure 3.10 – Exemple d’un réseau de neurones Feed-Forward

Dans les notations courantes, l’exposant [l] désigne la l^{ème} couche et l’indice (k) ou (j) désigne le k^{ème} nœud (neurone) d’une couche. Ainsi, entre le j^{ème} neurone de la l^{ème} couche et le k^{ème} neurone de la (l-1)^{ème} couche, il existe une connexion qui a un poids de $w_{j,k}^{[l]}$ qui lui est associé. La formule d’activation générale pour chaque neurone est ci-dessous, où f [l] est la fonction d’activation de la l^{ème} couche :

$$a_j^{[l]} = f^{[l]}(w_{j,k}^{[l]} a_k^{[l-1]} + b_j^{[l]}) = f^{[l]}(z_j^{[l]}) \quad (3.15)$$

3.4.4 Entraînement d’un réseau de neurones

Pendant cette phase d’apprentissage, le réseau apprend en ajustant les paramètres de manière à pouvoir prédire l’étiquette de classe correcte des échantillons d’entrée. Les paramètres du modèle, dans ce cas, font référence aux poids et aux biais de chaque couche. Tout d’abord, les paramètres sont initialisés. De nombreux schémas d’initialisation ont été proposés dans la littérature. Ensuite, le réseau de neurones feed-forward est utilisé pour accepter une entrée x et produire une sortie \hat{y} , les informations circulent dans le réseau. L’entrée x fournit l’information initiale qui se propage ensuite jusqu’aux unités cachées de chaque couche et produit finalement \hat{y} . C’est ce qu’on appelle forward propagation.

Avec ces sorties \hat{y} , et connaissant la valeur réelle de la sortie y, la fonction objectif peut être calculée, ce qui produit un coût scalaire $J(\omega, b)$. Après cela, l’erreur mesurée par la fonction de coût est propagée à travers chaque couche dans le sens inverse pour calculer la contribution d’erreur de la connexion de chaque neurone, jusqu’à ce qu’elle atteigne la couche d’entrée. Cette étape permet aux informations du coût de remonter ensuite dans le réseau pour calculer le gradient. Cette phase est appelée algorithme de rétro-propagation, souvent simplement appelé back-propagation. Les paramètres du modèle sont ensuite mis à jour par un algorithme d’optimisation tel que la descente de gradient.

Lorsque tous les poids et biais ont été mis à jour avec succès, l’ensemble du processus est

répété pour un autre lot entrant, jusqu'à ce que tous les ensembles de données d'apprentissage aient été entièrement parcourus, auquel cas, une époque d'apprentissage est atteinte. L'algorithme de rétro-propagation représente le cœur du processus d'apprentissage d'un réseau de neurones, car il s'agit de la procédure de mise à jour des paramètres d'apprentissage du modèle.

3.4.5 Réseaux de neurones récurrents RNN

Parmi les méthodes d'apprentissage automatique, les réseaux de neurones récurrents. Présentée comme une extension des réseaux de neurones feedforward, cette classe de réseaux de neurones est adaptée au traitement des données de séries temporelles et autres données séquentielles.

Ces algorithmes d'apprentissage profond sont couramment utilisés pour des problèmes ordinaux ou temporels, tels que la traduction de langues, le traitement du langage naturel, la reconnaissance vocale et le sous-titrage d'images.[28]

Ils se distinguent par leur "mémoire" (représenté par une variable h nommé état), car ils utilisent les informations des entrées précédentes pour influencer l'entrée et la sortie actuelles. Alors que les réseaux neuronaux profonds traditionnels supposent que les entrées et les sorties sont indépendantes les unes des autres, la sortie des réseaux neuronaux récurrents dépend des éléments antérieurs de la séquence.




Figure 3.11 – Comparaison entre un réseau de neurones récurrent (à gauche) et un réseau de neurones feedforward (à droite)

Une autre caractéristique distinctive des réseaux récurrents est qu'ils partagent des paramètres à travers chaque couche du réseau. Alors que les réseaux feedforward ont des poids différents pour chaque nœud, les réseaux neuronaux récurrents partagent le même paramètre de poids dans chaque couche du réseau.

Pour ajuster les poids et déterminer les gradients, les réseaux neuronaux récurrents s'appuient sur l'algorithme de rétropropagation dans le temps (BPTT), qui est légèrement différent de la rétropropagation traditionnelle car il est spécifique aux données de séquence. Les principes de la BPTT sont les mêmes que ceux de la rétropropagation traditionnelle, où le modèle s'entraîne

lui-même en calculant les erreurs entre sa couche de sortie et sa couche d'entrée.[29]

Tous les réseaux neuronaux récurrents ont la forme d'une chaîne de modules répétitifs de réseau neuronal. Dans les RNN standard, ce module répétitif aura une structure très simple, telle qu'une seule couche de tanh.




Figure 3.12 – RNN standard [30]

L'entraînement d'un RNN passe par plusieurs étapes, en commençant par prendre une séquence de données comme entrée et en initialisant l'état initial h_0 à 0. Le premier pas de temps de l'entrée est fourni au réseau. Il calcule ensuite son état actuel en utilisant l'ensemble de l'entrée actuelle et l'état précédent avec la formule

$$h_t = f(h_{t-1}, x_t) = \tanh(W_{hh}h_{t-1} + W_{xh}x_t + b_t) \quad (3.16)$$

où x_t l'entrée actuelle, h_t l'état actuel, h_{t-1} l'état précédent. W_{hh} , W_{xh} , b_h sont respectivement le poids du neurone récurrent, le poids du neurone d'entrée et le biais qui doivent être ajustés via l'entraînement. Le h_t actuel devient h_{t-1} pour le pas de temps suivant. Il est possible d'effectuer autant de pas de temps que nécessaire en fonction du problème et de réunir les informations de tous les états précédents. Une fois que tous les pas de temps sont terminés, l'état actuel final est utilisé pour calculer la sortie

$$y_t = g(W_{hy}h_t + b_y) \quad (3.17)$$

W_{hy} et b_y sont le poids du neurone de sortie et le biais de sortie et g une fonction d'activation. La sortie est ensuite comparée à la sortie réelle, c'est-à-dire la sortie cible, et l'erreur est générée. L'erreur est ensuite rétro-propagée dans le réseau pour mettre à jour les poids et le réseau (RNN) est ainsi formé. Au cours de ce processus, les RNN ont tendance à se heurter à deux problèmes, connus sous le nom de disparition du gradient et explosion du gradient. Ces problèmes sont définis par la taille du gradient, qui est la pente de la fonction objectif le long de la courbe d'erreur. Lorsque le gradient est trop petit, il continue à diminuer, en mettant à jour les paramètres de poids jusqu'à ce qu'ils deviennent insignifiants (c'est-à-dire 0). Le modèle ne fait

plus d'apprentissage.

De plus, le RNN fonctionne mieux lorsque chaque sortie y_t peut être estimée en utilisant le contexte local. Le contexte local fait référence à des informations proches du pas de temps t de la prédiction. Nous pourrions considérer que le RNN a une mémoire à court terme, ce qui n'est pas optimal lorsque nous devons prédire des événements sur la base d'une longue séquence de pas de temps. Pour résoudre ces problèmes, nous introduisons un modèle plus complexe appelé réseau de mémoire à long court terme (LSTM). Le LSTM sera mieux en mesure de mémoriser une information et de la conserver pendant de nombreuses étapes[28].

3.4.6 Réseau récurrent à mémoire courte (Long-Short Term Memory LSTM)

Les réseaux LSTM ont été introduits par les chercheurs allemands Sepp Hochreiter et Juergen Schmidhuber pour pallier le problème du gradient évanescent et est devenu l'une des architectures RNN les plus populaires à ce jour. [31] Il existe plusieurs variantes des réseaux LSTM dans la littérature, nous allons présenter la plus commune.




Figure 3.13 – Architecture standard d'un LSTM [30]

Alors que la cellule RNN standard ne contient qu'une seule unité de calcul, la cellule LSTM contient quatre blocs (ou couches) interactifs, chacun ayant un objectif bien défini. Ces unités sont décrites ci-dessous :

3.4.6.1 Couche de la porte de l'oubli

La porte d'oubli est un tenseur contenant des valeurs comprises entre 0 et 1 (grâce à la fonction sigmoïde) et qui sera multipliée par l'état précédent. Si une unité de la porte d'oubli a une valeur proche de 0, le LSTM oubliera l'état stocké dans l'unité correspondante de l'état de cellule précédent C_{t-1} . Si une unité dans la porte d'oubli a une valeur proche de 1, le LSTM se souviendra principalement de la valeur correspondante dans l'état stocké C_{t-1} . Il est calculé comme suit :

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (3.18)$$

3.4.6.2 Valeur candidate $\tilde{c}(t)$

La valeur candidate est un tenseur contenant des informations du pas de temps actuel qui peuvent être stockées dans l'état de cellule actuel $c(t)$. Les parties de la valeur candidate transmises dépendent de la porte de mise à jour. La valeur candidate est un tenseur contenant des valeurs comprises entre -1 et 1 et calculée par l'équation suivante :

$$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \quad (3.19)$$

3.4.6.3 Porte de mise à jour

Nous utilisons la porte de mise à jour pour décider quels aspects du candidat $\tilde{c}(t)$ ajouter à l'état de cellule $c(t)$. La porte de mise à jour décide quelles parties d'un tenseur candidat $\tilde{c}(t)$ sont transmises à l'état de cellule $c(t)$. C'est un tenseur contenant des valeurs comprises entre 0 et 1. Lorsqu'une unité de la porte de mise à jour est proche de 1, il permet de passer la valeur du candidat $\tilde{c}(t)$ sur l'état caché $c(t)$. Lorsqu'une unité dans la porte de mise à jour est proche de 0, cela empêche la valeur correspondante dans le candidat d'être passée à l'état caché. La porte de mise à jour a l'équation suivante :

$$i_t = (W_i[h_{t-1}, x_t] + b_i) \quad (3.20)$$

3.4.6.4 État de la cellule

$c(t)$ L'état de la cellule est la mémoire qui est transmise aux pas de temps futurs. Le nouvel état de cellule $c(t)$ est une combinaison de l'état de cellule précédent et de la valeur candidate. L'équation suivante est utilisée pour calculer l'état de la cellule, où nous désignons par le produit élément par élément :

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (3.21)$$

3.4.6.5 Porte de sortie

La porte de sortie décide de ce qui est envoyé comme prédiction (sortie) du pas de temps. C'est comme les autres portes. Il contient des valeurs allant de 0 à 1, calculées par :

$$\tilde{O}_t = \sigma(W_O[h_{t-1}, x_t] + b_O) \quad (3.22)$$

3.4.6.6 État caché

L'état caché est transmis au prochain pas de temps de la cellule LSTM. Il est utilisé pour déterminer les trois portes du pas de temps suivant. L'état caché est également utilisé pour la

prédiction $y(t)$. L'équation de l'état caché est :

$$h_t = \sigma(O_t * \tanh(C_t)) \quad (3.23)$$

Grâce à cette méthode, les LSTM permettent de préserver l'erreur qui peut être rétropropagée à travers le temps et les couches. En maintenant une erreur plus constante, ils permettent aux réseaux récurrents de continuer à apprendre sur de nombreux pas de temps, ouvrant ainsi une voie pour relier les causes et les effets à distance.

3.5 Apprentissage par transfert (Transfer Learning)

L'apprentissage par transfert est une méthode d'apprentissage automatique où un modèle développé pour une tâche est réutilisé comme point de départ d'un modèle pour une seconde tâche.[32]

Il s'agit d'une approche populaire dans le domaine de l'apprentissage profond qui permet d'accélérer l'entraînement et d'améliorer les performances des modèles d'apprentissage profond.

Dans l'apprentissage par transfert, nous formons d'abord un réseau de base sur un ensemble de données et une tâche de base, puis nous réaffectons les caractéristiques apprises, ou les transférons, à un deuxième réseau cible à former sur un ensemble de données et une tâche cible. Ce processus aura tendance à fonctionner si les caractéristiques sont générales, c'est-à-dire adaptées à la fois aux tâches de base et aux tâches cibles, plutôt que spécifiques à la tâche de base.

3.6 Conclusion

Dans ce chapitre, nous avons présenté les généralités sur les méthodes d'apprentissage machine et profond. Pour ce dernier, nous nous sommes intéressés aux réseaux de neurones récurrents et plus particulièrement aux réseaux LSTM.

Une description des travaux effectués avec les différentes méthodes sur notre ensemble de données et les résultats obtenus seront exposés dans le chapitre suivant.

Chapitre 4

Implémentation et résultats

4.1 Introduction

Le choix des modèles d'apprentissage et des paramètres est crucial pour assurer de bons résultats. L'évaluation de ces derniers a d'ailleurs besoin de différents critères. Nous exposons dans ce chapitre une description précise des modèles proposés et entraînés pour le travail de prédiction ainsi que les métriques utilisées pour la validation des modèles. Nous présentons ensuite les résultats obtenus et concluons sur l'efficacité de nos modèles à la prédiction de l'indice bispectral.

4.2 Matériel software

4.2.1 Google Colaboratory

Colaboratory, souvent raccourci en "Colab", est un produit de Google Research. Colab permet à n'importe qui d'écrire et d'exécuter le code Python et en tirant partie de ses bibliothèques par le biais du navigateur. Les notebooks Colab exécutent les codes sur les serveurs cloud de Google, ne nécessitent aucune configuration et permettent d'accéder à toute la puissance du matériel Google, y compris les GPU et TPU. [33]

4.2.2 Keras

La bibliothèque Keras permet d'interagir avec les algorithmes de réseaux de neurones profonds et d'apprentissage automatique, notamment Tensorflow3, Theano, Microsoft Cognitive Toolkit4 ou PlaidML. Conçue pour permettre une expérimentation rapide avec les réseaux de neurones profonds, elle se concentre sur son ergonomie, sa modularité et ses capacités d'extension. Elle a été développée dans le cadre du projet ONEIROS (Open-ended Neuro-Electronic Intelligent Robot Operating System).[34]

4.3 Critères d'évaluation

Afin d'évaluer les performances de nos modèles, différentes métriques ont été utilisées, chacune d'elle exposant un aspect sur les performances. Les métriques utilisées sont l'erreur quadratique moyenne, la médiane de l'erreur de performance et la médiane de l'erreur de performance absolue.

4.3.1 Racine de l'erreur quadratique moyenne (RMSE)

La racine de l'erreur quadratique ou RMSE (Root Mean Squared Error) est un indicateur très utilisé pour la validation d'un modèle de prédiction. Cet indice fournit une indication par

rapport à la dispersion ou la variabilité de la qualité de la prédiction et se calcule comme suit :

$$RMSE = \sqrt{\frac{\sum_{i=0}^n (y_i - \hat{y}_i)^2}{n}} \quad (4.1)$$

Avec n le nombre d'instances de données, y_i la sortie réelle et \hat{y}_i la sortie prédite par le modèle.

4.3.2 Médiane de l'erreur de performance (MDPE)

L'erreur de performance (Performance Error) est un indice représentant l'erreur relative de prédiction du modèle et se calcule comme suit :

$$PE = \frac{y_i - \hat{y}_i}{\hat{y}_i} \quad (4.2)$$

La MDPE (Median Performance Error), habituellement donnée en pourcentage (%) est simplement la médiane statistique de .

4.3.3 Médiane de l'erreur de performance absolue (MDAPE)

Par analogie avec le critère précédent, la MDAPE est la médiane statistique de la valeur absolue de l'erreur de performance et est donnée en pourcentage (%).

4.4 Modèle Gradient Boosting

4.4.1 Architecture

Les premiers essais accomplis pour ce travail ont été un travail de régression avec l'utilisation des différents modèles de renforcement de gradient. Le but étant de comparer les performances de chacun d'eux. Le choix des hyperparamètres s'est fait à la suite de différents tests. Ces essais ont été réalisés sur la première version de notre dataset, qui ne prend en compte que les variables s'affichant sur le moniteur du BIS. Dans une tentative d'améliorer les résultats de prédiction, un empilement de ces modèles a été effectué.

4.4.2 Résultats

Les résultats de la première approche sont résumés dans le tableau et l'histogramme suivant.

Algorithm	RMSE	MDPE (%)	MDAPE (%)
CATBoost	6.22	2.3	6.9
XGBoost	5.77	1.6	5.93
LightGBM	5.13	2.1	6.2
Stacking	4.6	1.4	5.01

Table 4.1 – Résultats approche Gradient Boosting

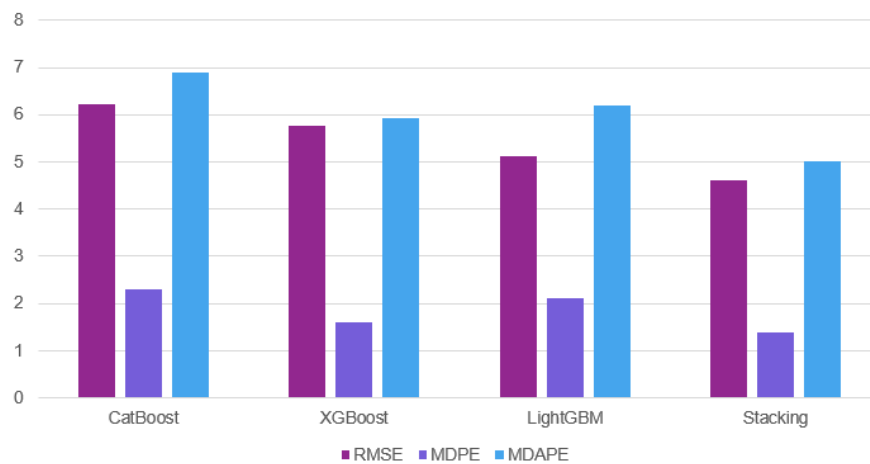


Figure 4.1 – Comparaison entre les modèles de la première approche

Comme nous nous y attendions, l’empilement de modèles a donné un meilleur résultat que l’utilisation de modèles individuellement.

4.5 Modèle Deep Learning (LSTM+feedforward network)

4.5.1 Architecture

La deuxième partie de ce travail consiste à utiliser les outils de l’apprentissage profond dans le but de prédire les valeurs de l’indice bispectral. L’apprentissage profond étant un ensemble de méthode demandant une certaine richesse de données, il a été décidé de prendre la deuxième

version de l'ensemble de données où sont ajoutés aux paramètres présents sur le moniteur du BIS, les informations cliniques du patient ainsi que l'historique de son dosage pour les deux anesthésiants propofol et rémifentanil. Comme ces variables sont paramètres du modèle PK-PD présenté dans la section 1.6.3, l'idée est de construire un modèle simulant le modèle PK-PD à l'aide d'un réseau de neurones LSTM suivi d'un réseau de neurones feedforward. Cette structure a été inspirée par les travaux [35] [36]. Après plusieurs tests de validation croisée, l'architecture choisie est la suivante :

- 8 cellules mémoires pour le réseau LSTM pour chaque historique d'infusion d'anesthésiant (donc 16 en tout)
- 16 neurones dans la couche cachée du réseau de neurones feedforward.

Les données temporelles du propofol sont l'entrée de 8 cellules mémoires du réseau LSTM, chacune d'elle calcule la quantité d'anesthésiant présent dans le compartiment du modèle PK. En utilisant la même structure, la même opération est effectuée pour les données temporelles du rémifentanil. La fonction d'activation pour la couche de la porte de l'oubli du réseau LSTM est la sigmoïde et celle de la cellule mémoire est la tangente hyperbolique tanh.

Aux 16 sorties du réseau LSTM sont ajoutées 4 covariables (âge, sexe, poids et taille du patient) et servent d'entrées au réseau feedforward (dont la couche d'entrée contient donc 20 neurones) et sont passés à travers une couche cachée de 16 neurones ayant une fonction d'activation ReLU sennée simuler le modèle PD pour le propofol et le remifentanil pour finir par la couche de sortie contenant un neurone activé par la fonction sigmoïde et qui donne la valeur prédite du BIS.

L'entraînement du modèle demandant beaucoup de temps et de puissance d'exécution, la méthode de transfer learning a été appliquée à partir d'un réseau de neurones pré-entraîné sur Keras. L'ajustement des poids se fait ensuite par la méthode d'optimisation de descente du gradient en appliquant la validation croisée pour éviter le surapprentissage des données.

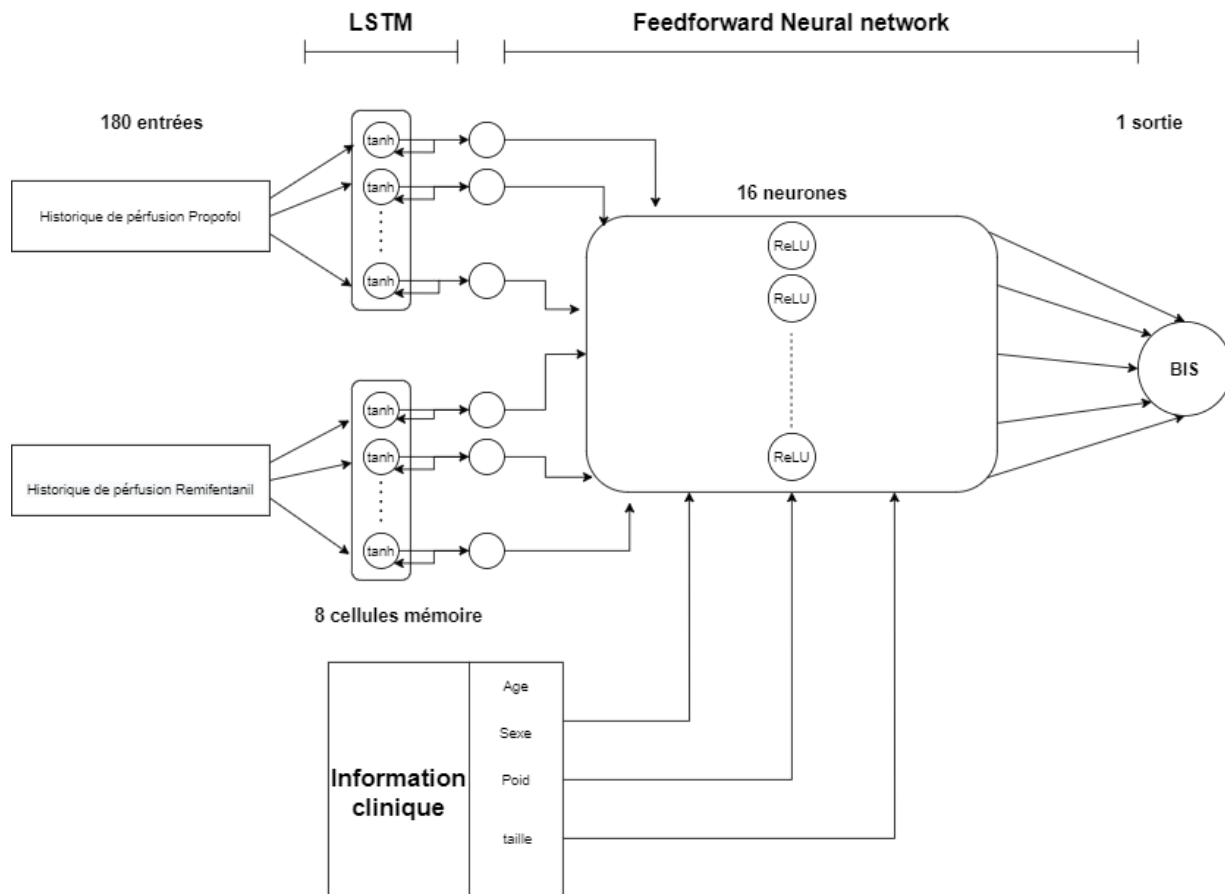


Figure 4.2 – Structure du modèle deep learning

4.5.2 Résultats

Les performances des modèles entraînés et leur comparatif est résumé dans le tableau suivant.

Algorithm	RMSE	MDPE (%)	MDAPE (%)
Deep learning	3.9	1.15	4.8
Modèle PK-PD	15	25	13.9

Table 4.2 – Résultats Modèle deep learning

4.6 Discussion

Nous remarquons que le modèle Deep learning surpasse le modèle de Gradient boosting dans toutes les métriques d'évaluation. De plus, le RMSE du second modèle est meilleur que celui du premier modèle (stacking) avec une différence de 0.7. Ainsi, nous soutenons que la caractéristique spatio-temporelle du second modèle l'aide à mieux modéliser les données et à obtenir des caractéristiques plus significatives.

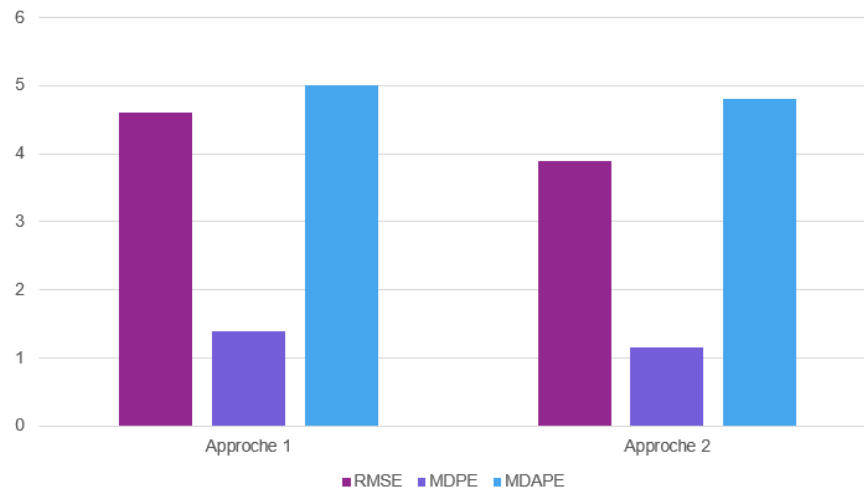


Figure 4.3 – Comparaison entre les deux approches

Nous avons également démontré que le modèle Deep learning est supérieur au modèle PK-PD traditionnel [12] pour prédire le BIS pendant les perfusions de propofol et de rémifentanyl contrôlées par cible chez les patients chirurgicaux.

L'avantage majeur de l'approche d'apprentissage profond est la possibilité de relier directement les paramètres cliniques aux prédictions du BIS, plutôt que les paramètres du modèle PK-PD, nous pouvons aussi envisager d'ajouter d'autres paramètres cliniques (performance cardiaque) à l'entrée du modèle feed-forward ce qui augmenterait sa performance et son extensibilité comparé au modèle traditionnel.

L'accumulation de données cliniques rendra le modèle d'apprentissage profond plus puissant et étendra son application à une variété de situations cliniques.

4.7 Conclusion

Au long de ce chapitre, nous avons présenté notre premier modèle basé sur un empilement d'algorithmes de gradient boosting, appliqué sur les données tirées des signaux EEG, ainsi que les résultats obtenus, le modèle effectue une prédiction de l'indice bispectral avec une erreur quadratique moyenne de 4.6.

Le second modèle a été implémenté, utilisant les avantages de l'apprentissage profond et de la particularité des réseaux LSTM à traiter les données séquentielles, ce modèle a donné un meilleur résultat avec une prédiction du BIS avec une erreur quadratique de 3.9. Enfin nous avons discuté et comparé ces résultats entre eux ainsi qu'avec le modèle original PK-PD.

Conclusion

Au long de ce projet, nous avons essayé d'exploiter les outils de l'intelligence artificielle afin de prédire la valeur de l'indice bispectral et d'effectuer un monitoring de la profondeur de l'anesthésie. Nous avons proposé un premier modèle en nous servant de l'apprentissage machine et plus particulièrement d'un empilement de modèles de gradient boosting afin de faire une régression sur les données extraites à partir des signaux EEG et visibles sur le moniteur BIS. Le second modèle proposé se base sur l'apprentissage profond avec une architecture composée d'un réseau neuronal LSTM suivi par un réseau feedforward. L'avantage de ce modèle au traitement des données temporelles a permis de concentrer l'apprentissage sur l'historique de dosage des deux agents anesthésiants : propofol et rémifentanyl. Le modèle PK-PD étant connu pour modéliser mathématiquement l'effet de l'anesthésie sur le corps à partir des données d'infusion des anesthésiant, il a été pris comme modèle à simuler avec cette approche.

Ces modèles ont tous deux montré leur efficacité en arrivant à prédire l'indice bispectral avec une erreur quadratique moyenne de 4.6 pour la première approche et 3.9 pour la seconde. Ces résultats sont nettement meilleurs par rapport aux résultats obtenus avec le modèle PK-PD.

Les modèles mis en œuvre dans cette thèse ont montré des résultats prometteurs. Cependant, ils doivent être testés de manière approfondie sur un ensemble de données plus volumineux pour une évaluation plus juste mais cela reste difficile à obtenir.

Précisons qu'il est strictement obligatoire de disposer d'ordinateurs performants pour pouvoir réaliser ces expérimentations car dans notre cas, du matériel très pauvre était disponible. Au cours du processus de formation, nous avons été confrontés à un grave problème de vitesse de calcul lente ainsi qu'à une mémoire très limitée où les données d'un sujet ne peuvent pas être téléchargées une fois dans la mémoire disponible.

En ce qui concerne les perspectives d'amélioration de ce travail, plusieurs options s'offrent à nous, . Il serait intéressant de généraliser ces modèles en incluant les historiques de dosages d'autres agents anesthésiants. Nous pourrions également avoir de meilleurs résultats s'il était possible de faire l'acquisition directe des données EEG brutes afin d'en effectuer l'analyse et d'en

tirer plus de paramètres déterminants pour le BIS.

En tant qu'automaticiens, la prochaine étape qu'il faudrait envisager serait de contrôler l'indice bispectral, et ce, en synthétisant un contrôleur qui déterminerait la dose nécessaire d'anesthésiant pour que cela se fasse de façon automatique sans l'intervention d'un anesthésiste.

Bibliographie

- [1] R. MATHUR, S. G. JASHVIN PATEL et A. JAIN., « Bispectral Index, » 2021.
- [2] « Monitoring during sedation, »
- [3] D. V. BILLARD, « UTILISATION CLINIQUE DE L'INDEX BISPECTRAL DE L'ELECTRO-ENCEPHALOGRAMME (BIS) EN ANESTHESIE, »
- [4] R. R. NUNES, I. M. M. CHAVES, J. C. G. de ALENCAR, S. B. FRANCO, Y. G. B. R. de OLIVEIRA et D. G. A. de MENEZES., « Bispectral Index and Other Processed Parameters of Electroencephalogram : an Update, » *Revista Brasileira de Anestesiologia*, t. 62, n° 1, p. 105-117, 2012.
- [5] (). « Bispectral Index Monitoring, » adresse : <https://nursekey.com/bispectral-index-monitoring/>.
- [6] B. CHANG, R. RAKER et P. S. GARCIA, « Bispectral Index Monitoring and Intraoperative Awareness, » *Anaesthesia Tutorial of The Week.Tutorial 416*, 31 december 2019.
- [7] H.-C. LEE, H.-G. RYU, Y. PARK, S. BINYOON, H.-W. SEONG MIYANG et C.-W. JUNG, « Data Driven Investigation of Bispectral Index Algorithm, » *Sci Rep*, t. 9, n° 13769, 2019. DOI : <https://doi.org/10.1038/s41598-019-50391-x>.
- [8] (). « Decision Tree Classification Algorithm, » adresse : <https://www.javatpoint.com/machine-learning-decision-tree-classification-algorithm>.
- [9] A. AL-HMOUZ, J. SHEN, R. AL-HMOUZ et J. YAN, « Modeling and Simulation of an Adaptive Neuro-Fuzzy Inference System (ANFIS) for Mobile Learning, » *IEEE TRANSACTIONS ON LEARNING TECHNOLOGIES*, t. 5, n° 3, JULY-SEPTEMBER 2012.
- [10] J. J. CHANG, S. SYAFIIE, R. K. R. AHMAD et T. A. LIM, « ANFIS Based Model for Bispectral Index Prediction, » 2014. DOI : 10.1007/978-3-319-07692-8_13, .
- [11] S. ABDULLA et P. WEN, « Depth of Anaesthesia Patient Models and Control, »
- [12] S. ABDULLA et P. WEN, « Depth of Anaesthesia Control Investigation Using Robust Dead-beat Control Technique, »
- [13] (). « BIS Dataset, » adresse : <https://vitaldb.net/dataset/>.

- [14] (). « What is data smoothing, » adresse : <https://corporatefinanceinstitute.com/resources/knowledge/other/data-smoothing/>.
- [15] S. SAMEERUDDIN. (). « HOW GRADIENT BOOSTING ALGORITHM WORKS, » adresse : <https://dataaspirant.com/gradient-boosting-algorithm/>.
- [16] WIKIPEDIA. (). « Gradient Boosting Algorithm, » adresse : https://en.wikipedia.org/wiki/Gradient_boosting#Algorithm.
- [17] H. S. R. PALLAPOTHU. (). « What's so special about CatBoost? » Adresse : <https://hanishrohit.medium.com/whats-so-special-about-catboost-335d64d754ae>.
- [18] J. BROWNLEE. (). « How to Develop a Light Gradient Boosted Machine (LightGBM) Ensemble, » adresse : <https://machinelearningmastery.com/light-gradient-boosted-machine-lightgbm-ensemble/>.
- [19] (). « LightGBM (Light Gradient Boosting Machine), » adresse : <https://www.geeksforgeeks.org/lightgbm-light-gradient-boosting-machine/>.
- [20] V. MORDE. (). « XGBoost Algorithm : Long May She Reign! » Adresse : <https://towardsdatascience.com/https-medium-com-vishalmorde-xgboost-algorithm-long-she-may-rein-edd9f99be63d>.
- [21] A. REZAZADEH, « AA Generalized Flow for B2B Sales Predictive Modeling : An Azure Machine-Learning Approach, » 2020. DOI : 10.3390/forecast2030015.
- [22] N. DONGES. (). « A COMPLETE GUIDE TO THE RANDOM FOREST ALGORITHM, » adresse : <https://builtin.com/data-science/random-forest-algorithm>.
- [23] A. SHARMA. (). « Decision Tree vs. Random Forest – Which Algorithm Should you Use? » Adresse : <https://www.analyticsvidhya.com/blog/2020/05/decision-tree-vs-random-forest-algorithm/>.
- [24] C. HANSEN. (). « Stack Machine Learning Models - Get Better Results, » adresse : <https://mlfromscratch.com/model-stacking-explained/#/>.
- [25] Q. REN, M. LI et S. HAN, « Tectonic discrimination of olivine in basalt using data mining techniques based on major elements : a comparative study from multiple perspectives, » *Big Earth Data*, t. 3, n° 3, p. 1-18, 2019. DOI : 10.1080/20964471.2019.1572452.
- [26] J. BROWNLEE. (). « A Gentle Introduction to k-fold Cross-Validation, » adresse : <https://machinelearningmastery.com/k-fold-cross-validation/>.
- [27] I. C. EDUCATION. (). « Neural Networks, » adresse : <https://www.ibm.com/cloud/learn/neural-networks>.
- [28] (). « Introduction to Recurrent Neural Network, » adresse : <https://www.geeksforgeeks.org/introduction-to-recurrent-neural-network/>.

- [29] —, (). « Recurrent Neural Networks, » adresse : <https://www.ibm.com/cloud/learn/recurrent-neural-networks>.
- [30] (). « Understanding LSTM Networks, » adresse : <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>.
- [31] (). « A Beginner's Guide to LSTMs and Recurrent Neural Networks, » adresse : <https://wiki.pathmind.com/lstm>.
- [32] J. BROWNLEE. (). « A Gentle Introduction to Transfer Learning for Deep Learning, » adresse : <https://machinelearningmastery.com/transfer-learning-for-deep-learning/>.
- [33] (). « Google Colaboratory, » adresse : <https://research.google.com/colaboratory/faq.html>.
- [34] (). « Keras, » adresse : <https://keras.io/>.
- [35] X. LIU, C. LIU, R. HUANG, H. ZHU, Q. LIU, S. MITRA et Y. WANG, « Long short-term memory recurrent neural network for pharmacokinetic-pharmacodynamic modeling, » DOI : 10.5414/CP203800.
- [36] M. SADRAWI, S.-Z. FAN, M. F. ABBOD, K.-K. JEN et J.-S. SHIEH, « Computational Depth of Anesthesia via Multiple Vital SignsBased on Artificial Neural Networks, » *Hindawi Publishing Corporation*, 2015. DOI : <http://dx.doi.org/10.1155/2015/536863>.

Chapitre 5

Annexe A

5.1 EEG

5.1.1 Introduction

L'électroencéphalographie est une technique non invasive d'imagerie fonctionnelle du cerveau qui mesure l'activité électrique générée par les cellules nerveuses par le biais d'électrodes placées sur le cuir chevelu. L'électroencéphalogramme est la transcription sous forme d'un tracé des variations dans le temps de l'activité électrique du cerveau. Depuis la publication des premiers résultats sur l'étude des signaux EEG en 1929, ces derniers sont non seulement utilisés pour étudier le fonctionnement du cerveau chez des individus sains, mais également pour diagnostiquer certaines maladies qui modifient l'activité électrique cérébrale (p.ex. épilepsie, migraines, troubles du sommeil).

5.1.2 Qu'est ce que les signaux EEG ?

L'électroencéphalographie (EEG) est une mesure des potentiels qui reflètent l'activité électrique du cerveau humain. Il s'agit d'un test facilement accessible qui fournit des preuves de la façon dont le cerveau fonctionne au fil du temps. L'EEG est largement utilisé par les médecins et les scientifiques pour étudier les fonctions cérébrales et diagnostiquer les troubles neurologiques. L'étude de l'activité électrique du cerveau, par le biais des enregistrements EEG, est l'un des outils les plus importants pour le diagnostic des maladies neurologiques, telles que l'épilepsie, les tumeurs cérébrales, les traumatismes crâniens, les troubles du sommeil, la démence et la surveillance de la profondeur de l'anesthésie pendant une opération. Il est également utile pour le traitement des anomalies, des troubles du comportement (par exemple, l'autisme), des troubles de l'attention, des problèmes d'apprentissage et des retards de langage. La première machine d'enregistrement EEG a été présentée au monde par Hans Berger en 1929. Berger, neuropsychiatre de l'université d'Iéna en Allemagne, a utilisé le terme allemand "elektrenkephalogramm" pour décrire les représentations graphiques des courants électriques générés dans le cerveau. Il a suggéré que les courants cérébraux changeaient en fonction de l'état fonctionnel du du cerveau, comme le sommeil, l'anesthésie et l'épilepsie. C'était une idée révolutionnaire qui a contribué à créer une nouvelle branche de la science médicale appelée neurophysiologie.

5.1.3 Système d'acquisition des signaux EEG

Pendant la phase d'acquisition de l'EEG, un certain nombre d'électrodes sont placés à différents endroits de la surface du cuir chevelu à l'aide de colles temporaires. Chaque électrode est connectée à un amplificateur (un amplificateur par paire d'électrodes) et à une machine d'enregistrement EEG. Enfin, les signaux électriques du cerveau sont convertis en lignes ondulées sur un écran d'ordinateur pour enregistrer les résultats. La figure présente un exemple de la façon

dont les électrodes sont placées sur le cuir chevelu pendant l'enregistrement des signaux EEG et les signaux affichés sur un écran d'ordinateur.




Figure 5.1 – Enregistrement de signaux EEG

Il existe deux types d'EEG, en fonction de l'endroit où le signal est pris dans la tête : le cuir chevelu ou intracrânien. Pour l'EEG du cuir chevelu, de petites électrodes sont placées sur le cuir chevelu avec un bon contact mécanique et électrique. Des électrodes spéciales implantées dans le cerveau lors d'une intervention chirurgicale donnent lieu à un EEG intracrânien. En revanche, l'EEG mesuré directement à partir de la surface corticale à l'aide d'électrodes sous-durales est appelé électrocorticogramme (ECoG). L'amplitude d'un signal EEG est généralement comprise entre 1 et 100 μV chez un adulte normal, et elle est d'environ 10-20 mV lorsqu'elle est mesurée avec des électrodes sous-durales.

5.2 Placement des électrodes

La question de savoir comment placer les électrodes est importante, car les différents lobes cérébraux sont responsables du traitement de différents types d'activités. La méthode standard pour la localisation des électrodes du cuir chevelu est le système international d'électrodes 10-20. Les "10" et "20" représentent les distances réelles entre les électrodes voisines, soit 10% ou 20% de la surface totale avant-arrière ou droite-gauche du crâne. Les positions sont déterminées par les deux points suivants : le nasion, qui est le point situé entre le front et le nez, à la hauteur de l'oreille. front et le nez, au niveau des yeux, et l'inion, qui est la proéminence osseuse située à la base du crâne, sur la ligne médiane, au niveau des yeux. du crâne sur la ligne médiane à l'arrière de la tête.




Figure 5.2 – Le système international de placement des électrodes 10-20

Chaque emplacement utilise une lettre pour identifier le lobe et un chiffre pour identifier l'emplacement de l'hémisphère. Les lettres F, T, C, P et O signifient Frontal, Temporal, Central, Pariétal et Occipital, respectivement. Un "z" fait référence à une électrode placée sur le milieu. Les numéros pairs font référence aux positions des électrodes sur l'hémisphère droit, tandis que les numéros impairs font référence à celles sur l'hémisphère gauche.

5.3 Montages EEG communs

Étant donné qu'un signal de tension EEG représente les tensions à deux électrodes, l'affichage des signaux pour la machine de lecture EEG peut être configuré de plusieurs manières. Le placement des électrodes est appelé montage. L'EEG peut être surveillé avec les montages suivants :

5.3.1 Montage bipolaire

Une paire d'électrodes constitue généralement un canal. Chaque canal (forme d'onde) représente la différence entre deux électrodes adjacentes. L'ensemble du montage consiste en une série de ces canaux. Par exemple, nous présentons un schéma de montage bipolaire sur la figure, où le canal "Fp1-F3" représente la différence de tension entre l'électrode Fp1 et l'électrode F3. Le canal suivant dans le montage, "F3-C3", représente la différence de tension entre F3 et C3, et ainsi de suite, à travers l'ensemble du réseau d'électrodes.




Figure 5.3 – Illustration d'un montage bipolaire

5.3.2 Montage référentiel

Chaque canal représente la différence entre une certaine électrode et une électrode de référence conçue. Il n'y a pas de position standard pour cette référence. Elle est cependant à une position différente de celle des électrodes « d'enregistrement ». Les positions médianes sont souvent utilisées car elles n'amplifient pas le signal dans un hémisphère par rapport à l'autre. Une autre référence populaire est « oreilles liées », qui est une moyenne physique ou mathématique des électrodes attachées aux lobes des oreilles et aux mastoïdes.




Figure 5.4 – Illustration d'un montage référentiel où A2 est l'électrode de référence

5.3.3 Montage de référence moyen

Les sorties de tous les amplificateurs sont additionnées et moyennées, et ce signal moyenné est utilisé comme référence commune pour chaque canal.

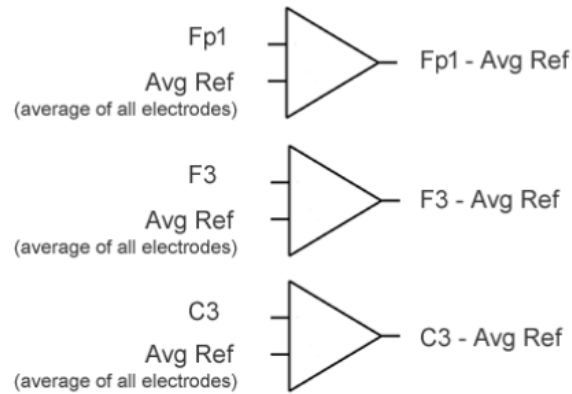


Figure 5.5 – Illustration d'un montage référentiel moyen

5.4 Fondamentaux des ondes EEG

Depuis les débuts de l'EEG, l'étude de différentes oscillations cérébrales et de leur relation avec différentes fonctions cérébrales a attiré l'attention des chercheurs.

Les oscillations cérébrales sont classées en bandes de fréquences et liées à différents états ou fonctions du cerveau. Dans cette section, une brève description des bandes de fréquences EEG est fournie.




Figure 5.6 – Signal EEG et ses bandes de fréquences correspondantes

5.4.1 Ondes Delta (jusqu'à 4 Hz)

Les ondes delta EEG sont des ondes cérébrales de grande amplitude et sont associées à des stades de sommeil profond. Les ondes delta sont également associées à différentes fonctions cérébrales autres que le sommeil profond, par exemple, les ondes delta frontales élevées chez les sujets éveillés sont associées à la plasticité corticale. Les bandes delta sont signalées comme des ondes cérébrales importantes dans le traitement cognitif, en particulier dans les études liées aux événements.

5.4.2 Ondes Thêta (4-8 Hz)

Les ondes thêta sont observées à l'état somnolent et plus fréquentes chez les enfants que chez les adultes. Chez l'adulte éveillé, sans faire aucune activité attentionnelle/cognitive, une activité thêta élevée est considérée comme anormale et associée à différents troubles cérébraux, par exemple, un thêta frontal élevé est lié à la non-réponse au traitement antidépresseur chez les patients dépressifs. Cependant, une activité thêta élevée joue un rôle important dans le traitement intentionnel et la mémoire de travail.

5.4.3 Ondes Alpha (8-12Hz)

Les ondes alpha peuvent être observées spontanément chez l'adulte normal pendant l'éveil et à l'état de relaxation, surtout en l'absence d'activité mentale. Pendant la condition des yeux

fermés, les ondes alpha sont proéminentes aux emplacements pariétaux. Le traitement attentionnel ou les tâches cognitives atténuent les ondes alpha. Les ondes alpha sont subdivisées en alpha inférieur et alpha supérieur. Il a été observé que l'activité alpha change avec la charge pendant la rétention de la mémoire de travail. De plus, la fréquence de pic alpha individuelle est un indicateur du facteur d'intelligence générale

5.4.4 Ondes Bêta (12-30 Hz)

Les ondes bêta ont des amplitudes plus faibles que les ondes alpha, delta et thêta. Traditionnellement, les ondes bêta sont subdivisées en bêta faible et bêta élevé. Les régions frontale et centrale du cerveau sont des endroits où des ondes bêta améliorées peuvent être observées pendant l'activité, la pensée anxieuse et la concentration profonde.

5.4.5 Ondes Gamma (au-dessus de 30 Hz)

Les ondes gamma sont des oscillations rapides et se trouvent généralement lors de la perception consciente. En raison de leur faible amplitude et de leur forte contamination par les artefacts musculaires, les ondes gamma sont sous-estimées et peu étudiées par rapport aux autres ondes cérébrales lentes. Une activité gamma élevée à des emplacements temporels est associée aux processus de mémoire. Des études de recherche ont rapporté que l'activité gamma est impliquée dans l'attention, la mémoire de travail et les processus à long terme. L'activité gamma est également impliquée dans les troubles psychiatriques tels que la schizophrénie, les hallucinations, la maladie d'Alzheimer et l'épilepsie.

5.5 Techniques d'analyse des signaux EEG

Les méthodes d'analyse EEG peuvent être classées dans les méthodes du domaine temporel, les méthodes du domaine fréquentiel, les méthodes du domaine temps-fréquence et les méthodes linéaires ou non linéaires.

5.5.1 Méthodes du domaine temporel

Les enregistrements EEG sont des fonctions temporelles non stationnaires et non linéaires. La prédiction linéaire est une méthode de domaine temporel dans laquelle la sortie est calculée à partir de l'entrée et des sorties précédentes. Principal component analysis (PCA), linear discriminant analysis (LDA) et independent component analysis (ICA) sont des méthodes non supervisées largement utilisées dans le domaine temporel pour résumer les données EEG. PCA est utilisé pour transformer les données de grande dimension en données de faible dimension tandis que ICA décompose les données de grande dimension en composants linéaires statistiquement

indépendants. Dans l'analyse des données EEG, l'ICA est le plus utilisé pour supprimer les artefacts. Alors que LDA est utilisé pour réduire les dimensions des ensembles de caractéristiques en trouvant des combinaisons linéaires de vecteurs de caractéristiques.

5.5.2 Méthodes du domaine fréquentiel

La méthode du domaine fréquentiel la plus utilisée est la transformée de Fourier (FT). On peut utiliser des méthodes paramétriques ou non paramétriques pour estimer le spectre de puissance à l'aide de FT. La méthode de Welch (non paramétrique), une version modifiée de la méthode du périodogramme largement utilisée, est généralement utilisée pour l'estimation de la densité spectrale de puissance (PSD). Mais ceci présente un inconvénient de fuite spectrale et est surmonté en employant des méthodes paramétriques. Les méthodes paramétriques offrent une meilleure résolution de fréquence en supposant que le signal EEG est un processus aléatoire stationnaire. La moyenne mobile (MA), la moyenne mobile auto-régressive (AR) et la moyenne mobile auto-régressive (ARMA) sont des méthodes paramétriques couramment appliquées.

5.5.3 Méthodes du domaine temps-fréquence

Les méthodes du domaine temporel et du domaine fréquentiel mentionnées ci-dessus ont des limites pour fournir respectivement les fréquences exactes impliquées dans un instant temporel particulier et l'information sur l'instant temporel. Pour surmonter ces limitations, la transformation en ondelettes (Wavelet Transform WT), une technique d'analyse basée sur le temps-fréquence, est largement utilisée pour obtenir des signaux de sous-bande décomposés multi-résolution en faisant passer le signal EEG à travers un banc de filtres.

5.5.4 Méthodes non linéaires

Des méthodes d'analyse non linéaires sont appliquées pour détecter le couplage entre les harmoniques dans le spectre du signal. Spectres d'ordre élevé (HOS), diverses mesures d'entropie, par exemple, entropie approximative (ApEn); entropie de Kolmogorov; L'entropie de l'échantillon, ainsi que l'exposant de Hurst, le plus grand exposant de Laypunov (LLE) sont des paramètres non linéaires largement utilisés pour l'analyse EEG.