



HAL
open science

Prévision du risque neuro-développemental du nouveau-né prématuré par classification automatique du signal EEG

Yasser Alhajjar

► **To cite this version:**

Yasser Alhajjar. Prévision du risque neuro-développemental du nouveau-né prématuré par classification automatique du signal EEG. Environnements Informatiques pour l'Apprentissage Humain. Université d'Angers, 2017. Français. NNT : 2017ANGE0020 . tel-01720427

HAL Id: tel-01720427

<https://theses.hal.science/tel-01720427>

Submitted on 1 Mar 2018

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Thèse de Doctorat

* (instructions page en annexe)

Yasser ALHAJJAR

*Mémoire présenté en vue de l'obtention du
grade de Docteur de l'Université d'Angers
sous le sceau de l'Université Bretagne Loire*

École doctorale : *Sciences et technologies de l'information et mathématiques*

Discipline : *Informatique*

Spécialité : *STIM*

Unité de recherche :

Soutenue le 24/10/2017

Thèse N° :

Prévision du risque neuro-développemental du nouveau-né prématuré par classification automatique du signal EEG

JURY

Rapporteurs : **François Jouen**, Dr DdR – Directeur d'Etude, Ecole Pratique des Hautes Etudes
Rafic Hage Chehadeh, Professeur des Universités, Université Libanaise

Examineurs : **Sylvie Nguyen**, Praticien Hospitalier, CHRU de Lille - Hôpital Albert Calmette
Patrick van Bogaert, Dr HdR – Professeur des Universités, Praticien Hospitalier
Anne Humeau, Dr HdR – Professeur des Universités, Institut Universitaire de Technologie

Invité(s) : **Abd El Salam AL HAJJAR**, Professeur des Universités, Université Libanaise

Directeur de Thèse : **Pierre CHAUVET**, Directeur délégué IMA, Université d'Angers

Co-directeur de Thèse (13) : **Bassam DAYA**, Professeur des Universités, Université Libanaise

Sommaire

Introduction générale	9
Contexte.....	10
Objectif.....	11
Contribution.....	12
Plan du rapport.....	13
1 Chapitre 1: Revue de la littérature	14
1.1 Introduction.....	15
1.2 Prématurité des nouveau-né.....	15
1.2.1 Définition et catégorisation.....	15
1.2.2 Risques médicaux.....	16
1.3 Signal ElectroEncéphaloGramme EEG.....	17
1.3.1 Evénements détectables.....	19
1.3.2 Amplitude (aEEG).....	20
1.3.3 EEG normal des enfants prématurés.....	23
1.3.4 EEG anormal des enfants prématurés.....	24
1.3.5 Artefacts rencontrés.....	25
1.4 Méthodes de prévision du devenir du nouveau-né prématuré.....	28
1.4.1 Analyse d'image obtenue par Imagerie à Résonance Magnétique.....	28
1.4.2 Analyse du signal EEG.....	31
1.5 Modèles de classification automatique.....	33
1.5.1 Régression linéaire multiple (MLR).....	33
1.5.2 Analyse discriminante linéaire (LDA).....	36
1.5.3 Machines à vecteurs de support (SVM).....	38
1.5.4 Arbre de décision (DT).....	41
1.5.5 Réseaux de neurones artificiels (ANN).....	46
1.6 Conclusion.....	49
2 Chapitre 2: Matériels et Méthodes	50
2.1 Introduction.....	51

2.2	Caractéristiques du signal EEG	51
2.3	Préparation des bases d'apprentissages.	56
2.3.1	Préparation de la Base BDD_IBI :	57
2.3.2	Préparation de la Base BDD_SEG :	60
2.4	Système d'apprentissage S_APP.....	65
2.4.1	Bases d'apprentissage et de test.	65
2.4.2	Méthodologie de l'apprentissage.	66
2.4.3	Paramètres d'évaluation.....	68
2.5	Conclusion.....	69
3	Chapitre 3: Résultats et discussion	70
3.1	Introduction.....	71
3.2	Application de S_APP sur BDD-IBI.....	72
3.2.1	Régression linéaire multiple.....	72
3.2.2	Analyse discriminante linéaire.....	73
3.2.3	Machine à Vecteurs de Supports.....	73
3.2.4	Réseau de neurones artificiel.....	74
3.2.5	Arbre de décision	75
3.2.6	Discussion des résultats.....	76
3.3	Application de S_APP sur BDD_SEG.....	78
3.3.1	Régression linéaire multiple.....	79
3.3.2	Analyse discriminante linéaire.....	79
3.3.3	Machine à Vecteurs de Supports.....	80
3.3.4	Réseau de neurones artificiel.....	81
3.3.5	Arbre de décision	82
3.3.6	Discussion des résultats.....	83
3.4	Choix des seuils dans la segmentation.	84
3.5	Proposition des caractéristiques utiles du signal EEG	86
3.6	Conclusion.....	89
4	Chapitre 4: Analyse des Données Corrélatives	91
4.1	Introduction.....	92

4.2	Corrélation produit des moments de Pearson	92
4.3	Matrice de corrélation	93
4.4	Détermination des caractéristiques pertinentes du signal EEG.....	94
4.5	Conclusion.....	98
5	Conclusion et perspective.....	100
	Reference	105
	Annexe	115

Liste des figures

Figure 1: Système 10-20, placement des électrodes par rapport à des repères anatomiques : le nasion et linion.	18
Figure 2: Exemple d'un signal EEG.....	18
Figure 3: signe épileptique	19
Figure 4: Un enregistrement aEEG de 90 minutes. La ligne A représente la valeur médiane maximale (12,3 μ V), la ligne B la valeur moyenne (8,8 μ V) et la ligne C la valeur médiane minimale (4,3 μ V).....	21
Figure 5 cinq catégories d'ondes EEG classées selon leur rythme.....	22
Figure 6: Interférence EOG sur l'EEG	26
Figure 7: Interférence ECG (Electrocardiogramme) sur l'EEG	26
Figure 8: procédé Atf_Esat.....	27
Figure 9: procédé Atf_Egd	28
Figure 10: procédé Atf_noE	28
Figure 11: Le procédé Atf_trans.....	28
Figure 12: substance blanche dans l'IRM	29
Figure 13: durée de l'IBI normal en fonction de l'AG	32
Figure 14: Régression linéaire simple	33
Figure 15: Régression linéaire multiple.	34
Figure 16: Exemple d'application à deux variables dépendantes.....	35
Figure 17: Exemple d'application à 3 variables dont 2 sont indépendantes liées à une troisième dépendante.....	35
Figure 18: Exemple d'application à 3 variables dont 2 sont dépendantes liées à une troisième dépendante.....	36
Figure 19: projection sur un axe pour réduire la dimension.....	37
Figure 20: hyperplan 1-dimensionnel qui sépare les cas en fonction de leurs catégories.....	38
Figure 21: marge optimisée entre les vecteurs supports.....	39
Figure 22: Points d'un cube tridimensionnel séparés par un plan bidimensionnel ...	40
Figure 23: points séparés par une région non linéaire	40
Figure 24: Séparations avec des limites très complexes.....	41
Figure 25: Réseau de neurones artificiel simple	47
Figure 26: algorithme de calcul de la fonction de transfert.....	47

Figure 27: Fonction de transfert sigmoïde.....	48
Figure 28: Fonction de transfert linéaire.....	49
Figure 29: Page d'accueil de EEGDiag	52
Figure 30: Exemple de fichier XML décrivant un analyseur	53
Figure 31: EEG avec deux phases d'activités (Bursts) séparées par un intervalle inter-bouffée (zone A).....	54
Figure 32: exemple du résultat de l'analyseur IBI_all_simple.....	55
Figure 33: entrée et sortie de EEGDiag	58
Figure 34 : exemple du fichier Excel obtenu par l'application de EEGdiag sur les EEG de ANR BB-EEG.....	58
Figure 35: segmentation du signal EEG en IBI, amplitude faible, moyenne et forte.	61
Figure 36: illustration de l'algorithme de SegEEG	62
Figure 37: Exemple de fichier XML décrivant SegEEG	63
Figure 38: exemple du fichier Excel obtenu par l'application de SegEEG sur les EEG de ANR BB-EEG.	63
Figure 39: Architecture générale du système d'apprentissage « S_APP ». Les méthodes d'apprentissage utilisées sont : SVM (support vector machine), MLR (régression Linéaire multiple), ANN (réseau de neurones artificiels), DT (arbre de décision) et LDA (analyse discriminante linéaire).....	66
Figure 40: schéma d'apprentissage	71
Figure 41: Réseau de neurone artificiel (ANN).....	74
Figure 42 : comparaison des résultats sur BDD_IBI	77
Figure 43: Réseau de neurone artificiel sur BDD_SEG.....	81
Figure 44: Arbre de décision	87
Figure 45: corrélation positive et négative.....	93
Figure 46: matrice de corrélation.....	93
Figure 47: matrice de corrélation entre les 20 attributs de BDD_SEG	94
Figure 48: Réseau de neurones artificiel ayant 17 variables d'entrées	97

Liste des tableaux

Tableau 1: catégorisation des ondes EEG	23
Tableau 2: représentation des résultats	68
Tableau 3: Résultat obtenu appliquant la régression linéaire multiple sur BDD_IBI.	72
Tableau 4: Résultats obtenus appliquant l'analyse discriminante linéaire sur BDD_IBI	73
Tableau 5: Résultats obtenus appliquant SVM sur BDD_IBI.....	74
Tableau 6: Résultats obtenus appliquant ANN sur BDD_IBI.....	75
Tableau 7: Résultats obtenus appliquant l'arbre de décision sur BDD_IBI	76
Tableau 8: comparaison des résultats des 5 méthodes sur BDD_IBI	77
Tableau 9: Résultats obtenus appliquant la régression linéaire multiple sur BDD_SEG	79
Tableau 10: Résultats obtenus appliquant l'analyse discriminante linéaire sur BDD_SEG	80
Tableau 11: Résultats obtenus appliquant SVM sur BDD_SEG	81
Tableau 12: Résultats obtenus appliquant ANN sur BDD_SEG.....	82
Tableau 13: Résultats obtenus appliquant l'arbre de décision sur BDD_SEG	83
Tableau 14: comparaison des résultats des 5 modèles sur BDD_IBI et BDD_SEG	83
Tableau 15: résultats obtenus après le changement des seuils utilisant ANN sur BDD_SEG	85
Tableau 16: comparaison des résultats des 2 seuils utilisant ANN sur BDD_SEG ..	86
Tableau 17: résultats obtenus utilisant ANN sur BDD_SEG ayant 20 attributs	88
Tableau 18: résultats obtenus utilisant l'arbre de décision sur BDD_SEG ayant 20 attributs	88
Tableau 19: comparaison des résultats de ANN et l'arbre de décision sur BDD_SEG	89
Tableau 20: Progression de la performance pour ANN.....	90
Tableau 21: comparaison des résultats des différentes séries utilisant ANN sur BDD_SEG	96
Tableau 22: résultats obtenus utilisant l'arbre de décision sur BDD_SEG ayant 17 attributs	97
Tableau 23: Comparaison des résultats avant et après la corrélation.....	98

Introduction générale

Contexte.....	10
Objectif.	11
Contribution.....	12
Plan du rapport.....	13

Contexte.

Un prématuré est un bébé né trois semaines avant la date prévue. La naissance naturelle (à terme) se fait après 40 semaines de grossesse. Le bébé prématuré risque d'avoir des organes incomplets, le plus souvent du système respiratoire et cardiaque, qui peuvent amplifier la morbidité et parfois causer la mort du bébé. Dans ce cas il est placé sous assistance car il n'est pas autonome et un certain nombre de complications peuvent survenir, surtout durant le premier mois jusqu'à deux ans après la naissance. Des services de réanimation néonatale peuvent aider à réduire ces complications si on arrive à établir les pronostics dès la naissance. L'électroencéphalogramme (EEG), qui mesure l'activité électrique du cerveau, est l'un des outils de prévision du devenir neurologique du prématuré. Un signal EEG est généralement formé d'intervalles de bouffées (activité) et inter-bouffées (aplatissement ou IBI) selon l'activité électrique du cerveau. Plusieurs études récentes ont montré que la durée du plus long IBI dans l'EEG est fortement corrélée avec une évolution anormale du cerveau [1]. Chez le nouveau-né prématuré l'EEG a la particularité d'être physiologiquement discontinu, constitué d'une alternance de périodes d'activité et de périodes d'aplatissement. Cette discontinuité évolue très rapidement au cours de la période de prématurité de 26 à 36 semaines [2].

Actuellement, plusieurs projets ont permis la détection automatique des IBI, mais la classification de l'EEG en normal ou pathologique reste toujours manuelle sans aucune aide logicielle.

Le projet ANR BB-EEG a pour objectif de mettre à disposition des hôpitaux une plateforme d'aide à l'interprétation de l'EEG du nouveau-né. Ce projet s'inscrit dans le développement de la télésanté, plus particulièrement dans les applications de la télémédecine à un domaine d'interprétation des signaux et images biomédicaux. Ce projet, qui a reçu le soutien fin 2010 de l'Agence Nationale de la Recherche, est dirigé par le Pr Sylvie NGuyen (Neuropédiatre, Centre Hospitalier Universitaire d'Angers) et mené par un consortium formé de plusieurs hôpitaux de la Région Pays de la Loire, de sociétés informatiques Nantaises, du laboratoire LARIS (Université d'Angers) et de l'Institut de Mathématiques Appliquées (UCO). Le projet ANR BB-EEG a disposé d'un ensemble de 397 dossiers de nouveau-nés prématurés pour être utilisés dans les recherches qui aident à trouver des caractéristiques dans le

signal EEG utiles dans la prévision d'un état neurologique anormal du nouveau-né prématuré. Chaque dossier contient un enregistrement EEG et un rapport concernant des informations sur le bébé à la naissance et un diagnostic 2 ans plus tard (normal, pathologique ou douteux). Une application appelée EEGDiag a été construite sous la responsabilité de Pr Pierre Chauvet pour analyser le signal EEG et en extraire les caractéristiques utiles à la prévision automatisée du devenir du prématuré. Cette application contient des algorithmes qui segmentent l'enregistrement EEG en phases d'activité et d'aplatissement et calculent sur chaque phase des mesures (telles que le nombre des phases, durée moyenne de la phase, la durée de la plus longue phase...) qui peuvent être utilisés dans la classification automatique de l'EEG. D'autre part cette application est gérée d'une manière dynamique en se basant sur un mécanisme de plug-in qui permet de l'enrichir en lui intégrant des nouvelles fonctions.

L'application de EEGDiag aux 397 signaux EEG disponibles dans le cadre du projet ANR BB-EEG a généré une base de données formé de 397 instances contenant des mesures calculées par EEGDiag sur chaque signal avec un score qui est la classification normale, pathologique ou douteuse. Cet ensemble de données peut être utilisé dans l'apprentissage afin de proposer un système de classification performant, qui permet d'émettre un pronostic de l'état pathologique / non pathologique de l'enfant prématuré dès sa naissance.

Objectif.

L'objectif de la thèse consiste à construire des modèles performants pour évaluer la pertinence des variables construites par EEGDiag dans la classification de l'EEG en normal ou pathologique. Il s'agit ensuite de trouver de nouvelles variables explicatives qui donnent de meilleurs résultats et de construire les outils nécessaires à leurs extractions du signal EEG. Une partie importante de la thèse sera consacrée à la recherche des variables expliquant au mieux l'état pathologique ou non du prématuré avec l'aide des neuropédiatres.

Tous les outils qui seront construits passeront par une étape de validation pour les intégrer ou non dans le logiciel EEGDiag. Ils devront prendre en compte un certain nombre de contraintes pour une utilisation en routine, en particulier la robustesse face aux artefacts, la vitesse d'exécution et la facilité d'interprétation.

Contribution.

Nous avons utilisé 80% de l'ensemble des données pour l'apprentissage et les 20% restant pour le test dans le but de valider notre système de classification automatique. Ce système permet de prévoir un risque sur la maturation cérébrale dès la naissance qui peut se traduire par un état pathologique à 2 ans. Pour optimiser la performance de ce système, plusieurs études ont été réalisées. Dans la première partie nous avons effectué une normalisation de l'ensemble des données en équilibrant le nombre des instances de chaque classe pour obtenir 740 instances. Puis nous avons appliqué plusieurs modèles issus de l'intelligence artificielle pour évaluer la pertinence des variables détectées par EEGDiag dans la classification de l'EEG en normal, pathologique ou douteux.

La deuxième partie comporte une étude bibliographique sur les variables expliquant au mieux l'état pathologique ou non du prématuré. Cette étude bibliographique avec les annotations des neuro-pédiatres nous a amené à subdiviser l'amplitude des bouffées du signal EEG en trois catégories : faible, moyenne et forte, et à choisir les intervalles de ces trois catégories en essayant plusieurs seuils définis dans la littérature. Nous avons développé dans EEGDiag un nouvel analyseur qui détecte les anciens variables des 4 intervalles : inter-bouffée, bouffée faible, bouffée moyenne et bouffée forte. Nous avons éliminé dans ce nouvel analyseur les intervalles d'une durée de moins de 2 secondes pour éviter les artefacts causés par un clin d'œil ou le battement du cœur, qui apparaissent dans l'enregistrement EEG avec une très forte amplitude. En appliquant cet analyseur sur les 740 enregistrements, nous avons obtenu une nouvelle base d'apprentissage formé de 26 vecteurs d'entrée et un vecteur de sortie qui correspond à la classe (trois modalités : normal, pathologique ou douteux).

La troisième partie, basée sur une analyse corrélative de données, a permis d'extraire des relations d'indépendance et de redondance entre les variables que nous avons construites, pour réduire leur nombre. Ceci nous a permis d'obtenir 17 variables décisives et de sélectionner ainsi la meilleure série pour optimiser notre système. A chaque étape, nous avons répété l'application de nos modèles et nous avons évalué les performances des différents ensembles de variables proposés.

L'évaluation du nouveau système a permis d'atteindre une performance de 100% pour la classe pathologique, 90% pour la classe douteuse et 90,6% pour la classe normale. Ce système possède une bonne sensibilité à la prévision de l'état neurologique du nouveau-né prématuré et peut servir comme aide à la décision dans le traitement clinique.

Plan du rapport.

Dans le premier chapitre nous allons introduire et définir les éléments clefs de la thèse : la prématurité, le signal EEG, la prévision des pronostics du prématuré et les modèles de classification automatique. Dans le deuxième chapitre nous allons présenter l'application EEGDiag et les caractéristiques qu'elle détecte dans le signal EEG, et nous allons préparer deux bases de données utilisées dans l'apprentissage : la première BDD-IBI se basant sur les intervalles bouffés et inter-bouffés, la deuxième BDD-SEG se basant sur la segmentation de l'amplitude du signal EEG. Dans le troisième chapitre nous allons appliquer l'apprentissage sur les deux bases de données utilisant plusieurs modèles de classification et discuter leurs résultats. Dans le quatrième chapitre, nous allons faire une étude corrélative entre les caractéristiques trouvées pour réduire leur nombre en simplifiant les caractéristiques redondantes. Enfin, nous allons présenter nos conclusions et nos perspectives.

1 Chapitre 1: Revue de la littérature

1.1	Introduction.....	15
1.2	Prématurité des nouveau-né.....	15
1.2.1	Définition et catégorisation.....	15
1.2.2	Risques médicaux.....	16
1.3	Signal ElectroEncéphaloGramme EEG.....	17
1.3.1	Evénements détectables.....	19
1.3.2	Amplitude (aEEG)	20
1.3.3	EEG normal des enfants prématurés.....	23
1.3.4	EEG anormal des enfants prématurés	24
1.3.5	Artefacts rencontrés.....	25
1.4	Méthodes de prévision du devenir du nouveau-né prématuré.....	28
1.4.1	Analyse d'image obtenue par Imagerie à Résonance Magnétique	28
1.4.2	Analyse du signal EEG	31
1.5	Modèles de classification automatique.....	33
1.5.1	Régression linéaire multiple (MLR)	33
1.5.2	Analyse discriminante linéaire (LDA).....	36
1.5.3	Machines à vecteurs de support (SVM)	38
1.5.4	Arbre de décision (DT)	41
1.5.5	Réseaux de neurones artificiels (ANN)	46
1.6	Conclusion.....	49

1.1 Introduction

Dans ce chapitre nous allons définir et introduire tous les éléments nécessaires au développement de notre thèse. Dans la première partie, nous allons expliquer la prématurité et la catégoriser en fonction de l'âge gestationnel en prématurité tardive (34-36 semaines), modérée (32-33 semaines), très prématuré (28-31 semaines) et extrêmement prématuré (<28 semaines). Ensuite, nous allons citer les risques qui menacent physiologiquement un prématuré dans chaque phase. Dans la deuxième partie, Nous allons expliquer les différentes formes du signal EEG, ses changements durant la prématurité, les pathologies détectables par le signal EEG, les formes normales et anormales dans le signal, ainsi que les artefacts qui peuvent être signalé durant l'enregistrement. Dans la troisième partie, Nous allons parler des deux méthodes essentielles dans la détection des pronostics de l'état pathologique d'un prématuré dès sa naissance : la première en fonction des substances blanches dans l'imagerie résonance magnétique (IRM) et la deuxième en fonction des aplatissements dans le signal EEG. Enfin, nous allons citer différents modèles de classification pour en choisir ceux que nous allons utiliser dans notre travail.

1.2 Prématurité des nouveau-né

Un prématuré est un bébé né trois semaines avant la date prévue. La naissance naturelle (à terme) se fait après 40 semaines de grossesse. Le bébé prématuré risque d'avoir des organes incomplets, le plus souvent du système respiratoire et cardiaque, qui peuvent amplifier la morbidité et parfois causer la mortalité du bébé. Dans ce cas il est placé sous assistance car il n'est pas autonome et un certain nombre de complications peuvent survenir surtout durant le premier mois jusqu'à deux ans après la naissance. Des services de réanimation néonatale peuvent aider à réduire ces complications si on arrive à établir les pronostics dès la naissance.

1.2.1 Définition et catégorisation

Par convention, l'âge gestationnel (AG) se réfère au temps entre le premier jour de la dernière période menstruelle d'une femme et la naissance. La fécondation se produit généralement deux semaines après le premier jour de la dernière période menstruelle. AG comprend cet écart de deux semaines. En utilisant cette définition, l'âge gestationnel à la naissance est de 40 semaines. Toutes les naissances dans

les 21 jours avant et 14 jours après 40 semaines sont définies comme naissance à terme. L'Organisation mondiale de la santé (OMS) définit la prématurité ou la naissance prématurée par la période durant laquelle les bébés sont nés avant 37 semaines à partir du premier jour de la dernière période menstruelle. Des données récentes indiquent qu'environ 10% des nouveau-nés dans le monde sont prématurés [3].

L'âge gestationnel de la prématurité est divisé en différentes catégories, et les naissances dans chaque catégorie sont plus rares à mesure que l'AG diminue. Ces catégories sont les prématurités tardives (34-36 semaines), modérées (32-33 semaines), les grandes prématurités (28-31 semaines) et les extrêmes prématurités (<28 semaines). Le poids à la naissance est linéairement corrélé avec la prématurité et a sa propre catégorisation. Les catégories typiques de poids à la naissance sont le poids faible <2500 g, le poids très faible <1500g et le poids extrêmement faible <1000g. Habituellement la relation entre l'âge gestationnel et le poids est importante : les études choisissent le poids à la naissance ou l'AG pour déclarer les risques neuro-développementaux, mais pas les deux. Le poids normal d'un bébé né à terme est supérieur à 2500g. Le poids des bébés nés avant 33 semaines est inférieur à 1500g et le poids des bébés nés avant 30 semaines peut être inférieur à 1000g.

1.2.2 Risques médicaux

Les bébés prématurés ont un risque de morbidité et de mortalité aggravée. Les statistiques indiquent que 27% des bébés prématurés vont mourir dans la première année de leur vie [4]. Plus l'AG est précoce, plus le risque de morbidité et de mortalité est élevé. La relation entre la mortalité et l'AG n'est pas linéaire mais exponentielle. Bien que seulement 3-4% des naissances soient avant 34 semaines, elles représentent la majorité des décès néonataux. [5].

Les nouveau-nés prématurés qui survivent ont toujours le risque d'avoir une incapacité qui peut induire à un handicap selon trois grands domaines : mentale (déficience neuro-développementale), physique (développement neuro-moteur) et sensorielle (vision, audition). Les études ont montré que près de la moitié des nourrissons nés à 24-28 semaines de gestation seront handicapés à 5 ans, ainsi qu'environ le tiers des nourrissons nés plus tard (29-32 semaines de gestation) [6].

Le bébé prématuré a le risque d'avoir les problèmes suivants :

- Hypothermie, parce qu'ils ne peuvent pas produire et retenir suffisamment de chaleur pour maintenir leur température corporelle [7].
- Hypoglycémie, surtout si ils sont extrêmement prématurées. Ils peuvent également avoir une hypocalcémie. Ces deux problèmes peuvent causer des lésions cérébrales à long terme [7].
- Le syndrome de détresse respiratoire est un risque qui augmente avec la prématurité du bébé, si les niveaux d'oxygène sont trop élevés, le bébé prématuré est sensible au fibroblaste rétrolental et la cécité [7].
- l'ictère néonatal à un niveau inférieur de bilirubine [8].
- l'infection et l'entérite nécrosante.
- L'hémorragie cérébrale intra ventriculaire avec des effets graves à long terme.
- Un neuro-développement faible [9].
- Une paralysie cérébrale pour les prématurés nés entre 28-31 semaines [10].
- Une rétinopathie de la prématurité [11].
- Des maladies et infections respiratoires chez les enfants extrêmement prématurités (poids de naissance 500-999 g [12].
- Une anomalie de la fonction pulmonaire pendant l'enfance [13]. Des déficiences cognitives et neuromotrices à 5 ans. Nombre de ces enfants ont besoin d'un niveau élevé de soins spécialisés [14].

1.3 Signal ElectroEncéphaloGramme EEG

L'électroencéphalogramme, ou EEG, est une mesure de l'activité électrique du cerveau (les ondes cérébrales) à travers la peau. Comparable à l'électrocardiogramme qui permet d'étudier le fonctionnement du cœur, l'EEG est un examen indolore et non-invasif qui renseigne sur l'activité neurophysiologique du cerveau au cours du temps et en particulier du cortex cérébral, dans un but diagnostique en neurologie ainsi que dans la recherche en neurosciences cognitives.

Depuis les premiers travaux de Sarnat en 1976, l'EEG s'est imposé comme un outil indispensable à l'évaluation de la souffrance cérébrale [15]. Son principe repose sur une analyse visuelle codifiée permettant de reconnaître des caractéristiques : par exemple tracé inactif, tracé paroxystique, tracés discontinus. Au cours de ce test, des petits capteurs appelés électrodes sont fixés sur le cuir chevelu du patient. L'activité électrique captée par chaque électrode est enregistrée sous forme de tracé EEG.

Afin de standardiser le placement des électrodes, Le « *Committee of the International Federation of Societies for Electroencephalography and Clinical Neurophysiology* » a proposé un système de référence qui est maintenant connu sous la dénomination « 10-20 ». L'idée est de prendre des points de repères anatomiques et à partir de ceux-ci de placer les électrodes avec des intervalles de 10 ou 20% de la distance entre les marques (Figure 1). Chaque électrode possède un code alphanumérique standard lié à sa position.

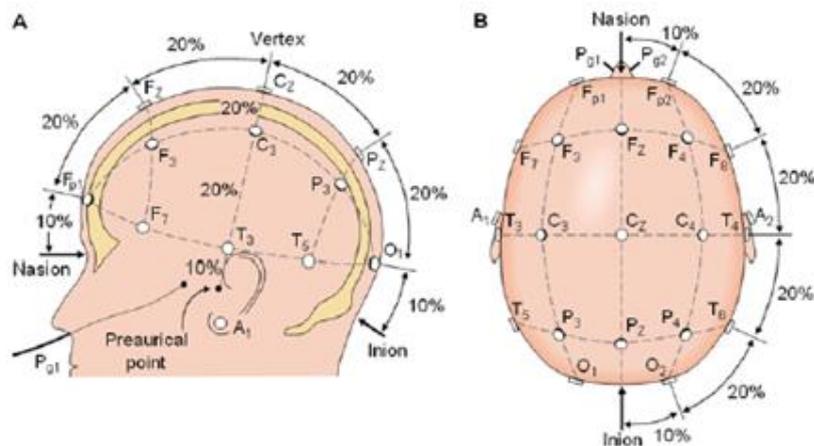


Figure 1: Système 10-20, placement des électrodes par rapport à des repères anatomiques : le nasion et inion.

L'activité bioélectrique cérébrale correspond à des différences de potentiel électrique entre deux électrodes. Un montage EEG correspond donc à une combinaison de couples d'électrodes. Il existe des montages bipolaires et des montages référentiels (ou mono polaires). Dans un montage bipolaire, le signal mesuré est la différence entre un pôle positif et un pôle négatif, alors que dans un montage référentiel, le signal mesuré ne provient que d'un pôle, le pôle opposé étant commun à tous les couples d'électrodes.

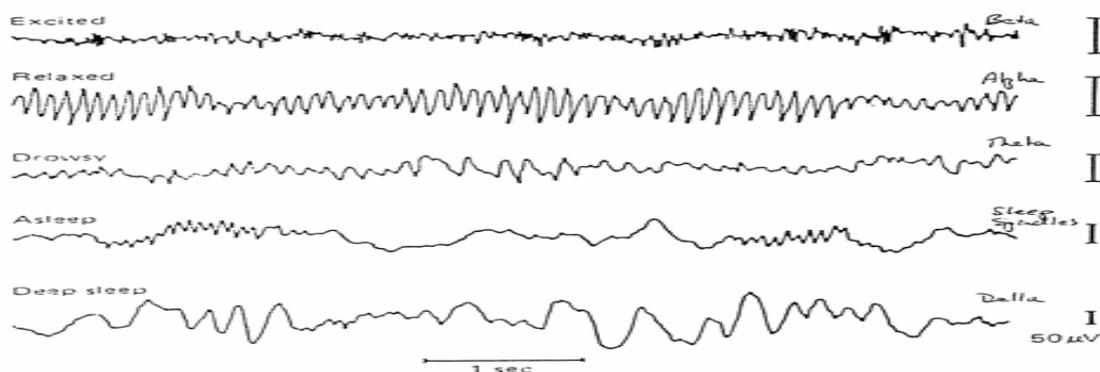


Figure 2: Exemple d'un signal EEG.

1.3.1 Événements détectables

L'épilepsie constitue la pathologie la plus étudiée par électro-encéphalographie. Elle apparaît sous forme d'une activité inégale ou des changements importants du voltage des ondes cérébrales. Dans l'EEG, la crise d'épilepsie se caractérise par des ondes pointues de grande amplitude et de courtes durées [16].

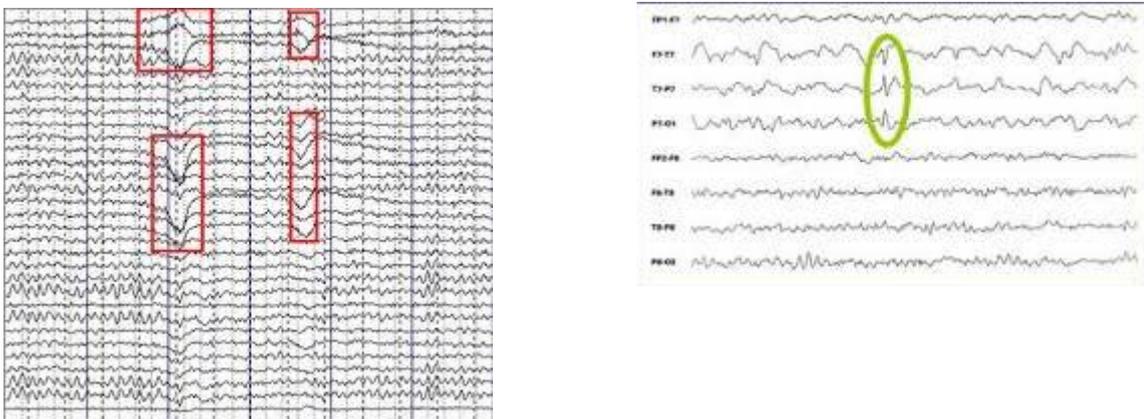


Figure 3: signe épileptique

Les patterns EEG lors des crises peuvent être de plusieurs types différents, dépendant essentiellement du type de crise en présence. On peut distinguer :

- Une décharge de pointes ondes ou encore poly-pointes ondes.
- Une oscillation basse fréquence (thêta focale) : à environ 5 Hz.
- Une oscillation à plus haute fréquence : à environ 10 Hz (La crise généralisée de type absence se caractérise par une bouffée de pointes ondes typiquement à 3 Hz pendant quelques secondes).

D'autres pathologies du système nerveux sont détectées par l'EEG comme le diagnostic d'un état de mort cérébrale (tracé nul), Les troubles de la conscience (coma, confusion), Les lésions cérébrales (hémorragie cérébrales,...). L'EEG permet de mesurer l'activité cérébrale avec une grande précision temporelle, milliseconde par milliseconde. Elle renseigne donc sur d'éventuelles altérations fonctionnelles dans la dynamique de l'activité neuro électrique (ralentissement, activité EEG pathologique, organisation "critique" de l'activité...).

Par contre, le potentiel électrique mesuré en EEG est très faible et très diffusé ce qui limite l'information spatiale fournie par l'examen EEG. Il est donc difficile de

déterminer quelles sont les structures cérébrales d'où provient le signal EEG qu'il soit normal ou pathologique.

Les fréquences des ondes cérébrales s'étendent de 0,25 Hz à environ 60 Hz, l'état de conscience de la personne (éveil, sommeil, ou rêve) ayant une importance déterminante sur la fréquence de l'électro-encéphalogramme.

1.3.2 Amplitude (aEEG)

Le signal aEEG est dérivé du signal EEG original en le traitant pour amplifier numériquement, lisser, rectifier et compresser l'EEG brut sur un affichage logarithmique par intervalle [17]. Les profils de la fonction cérébrale varient selon la maturation, l'état de sommeil / réveil ou les blessures, et reflètent la fonction cérébrale de fond au cours du temps (1, 6). En particulier, l'aEEG capture les deux principales caractéristiques de base observées sur le cerveau des nouveau-nés : la continuité et la discontinuité, et le cycle qui représente une transition de l'une à l'autre. Elles sont évaluées en termes de bordure inférieure et supérieure, et de la différence entre ces bordures dans l'image graphique [18].

La continuité est le profil de la fonction cérébrale représenté par une activité de signal EEG ininterrompue, avec une amplitude constante dans une plage compatible avec le développement gestationnel (en l'absence de blessures, de maladies ou de certains médicaments). L'immaturité et les médicaments tels que les sédatifs réduisent la continuité du signal et l'amplitude du bord inférieur qui en résulte reflétée par l'aEEG [19]. Si le bord inférieur d'une tendance aEEG est constamment au-dessus de 5 microVolts (μV), l'activité est généralement définie comme continue. En revanche, la discontinuité se compose d'amplitudes mixtes modelées sous la forme de bouffées de signaux EEG à amplitude élevée intercalées avec une amplitude proche de zéro, intervalles inter-bouffées. Le signal bouffées et inter-bouffées produit un motif graphique aEEG interrompu, moins dense que l'image formée par la continuité. Lorsqu'il est mis en évidence par aEEG, le signal EEG discontinu moins dense représente graphiquement une limite inférieure à moins de $5\mu\text{V}$ (habituellement $3-5\mu\text{V}$) avec une limite supérieure simultanément élevée. La large bande passante qui en résulte entre les deux frontières est une classification visuelle de la discontinuité [20]. Les bouffées et les

inter-bouffées sont des caractéristiques de la fonction cérébrale prématurée décrite pendant des décennies.

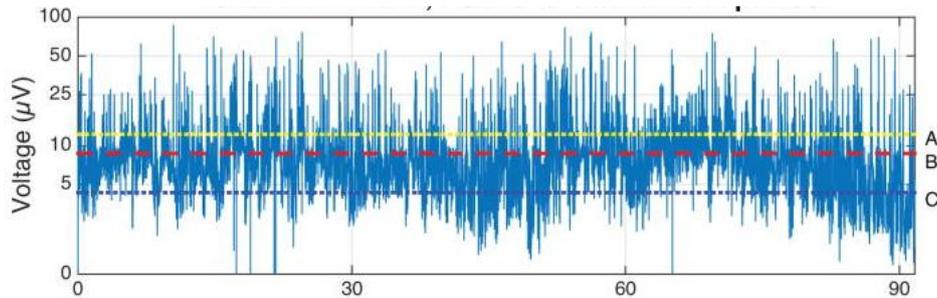


Figure 4: Un enregistrement aEEG de 90 minutes. La ligne A représente la valeur médiane maximale (12,3 μV), la ligne B la valeur moyenne (8,8 μV) et la ligne C la valeur médiane minimale (4,3 μV)

Bien qu'il y ait un débat dans la littérature sur le moment des changements cycliques évidents entre la continuité et la discontinuité et la relation avec le sommeil et le cycle de sillage, les premiers signes d'un cycle clair entre la discontinuité et la continuité ont été documentés pour un enfant en bonne santé ayant un AG plus que 29 semaines [21]. La continuité, la discontinuité et ce que l'on appelle couramment le cycle sommeil-veille entre les deux modèles forment la base de l'interprétation des données aEEG. Chez les nourrissons prématurés normaux, le signal de la fonction cérébrale se développe pour refléter un modèle aEEG essentiellement discontinu au début de la vie, et un signal plus continu lorsque le nourrisson approche de l'accouchement à terme.

On distingue 5 catégories principales d'ondes EEG en fonction de leurs rythmes et amplitudes [22] :

- Le rythme beta est présent lorsque l'on est éveillé et que l'on garde les yeux ouverts. Les ondes apparaissent de manière symétrique et leurs amplitudes sont faibles.
- Le rythme sigma est particulier puisqu'il correspond à un micro événement spécial du sommeil appelé fuseau.
- Le rythme alpha est une activité normale d'un adulte éveillé, mais il est surtout présent lorsque l'individu se relaxe et garde les yeux fermés. Il apparait simultanément des deux côtés de la tête généralement plus vers l'arrière qu'à l'avant, et est donc mieux visualisé sur un EEG occipital (Oz-A1) que sur un EEG central (Cz-A1) ou Frontal (FP1-A1). Il disparaît dès que le sujet ouvre les yeux ou en cas d'activité mentale.

- Le rythme thêta peut aussi bien être normal qu'anormal en fonction de l'âge et de la pathologie de la personne. En effet, il est tout à fait naturel s'il s'agit d'un adulte et que celui-ci est endormi. Par contre, si ce dernier est parfaitement éveillé, la présence d'ondes thêta peut être le signe d'un dysfonctionnement du cerveau.
- Le rythme delta n'est normal que si l'individu est plongé dans un sommeil profond. Les ondes correspondantes présentent alors des amplitudes généralement plus élevées que pour toutes les autres ondes et sont plus marquées sur un EEG frontal (FP1-A1) que central (Cz-A).

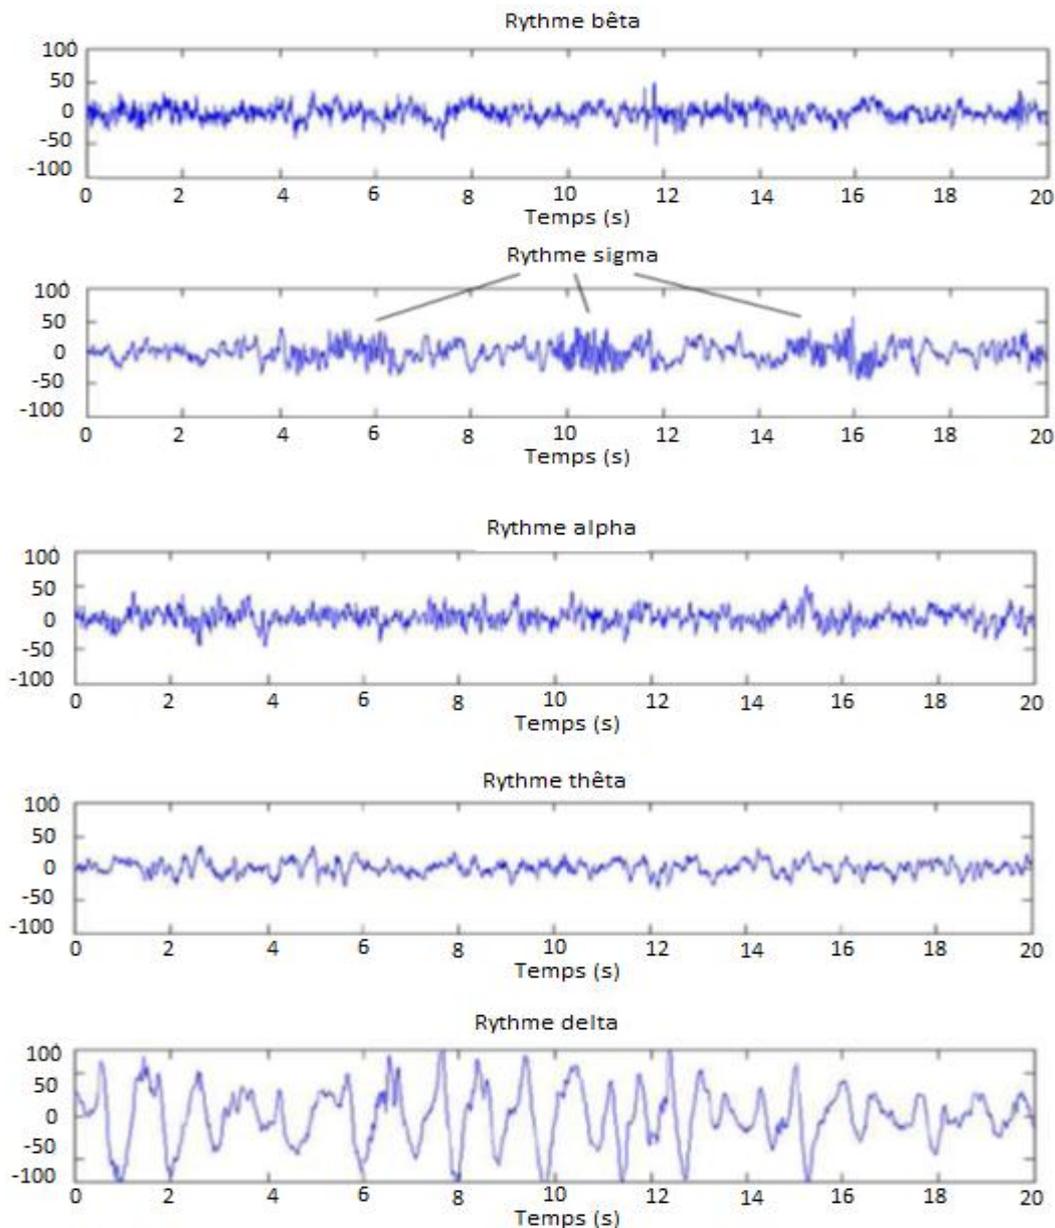


Figure 5 cinq catégories d'ondes EEG classées selon leur rythme

	Fréquences (Hz)	Amplitudes (μV)
Les ondes bêta	De 14 à 45	De 2 à 20
Les ondes sigma	De 12 à 14	De 5 à 100
Les ondes alpha	De 8 à 12	De 20 à 60
Les ondes thêta	De 3 à 8	De 5 à 100
Les ondes delta	De 0,5 à 3	De 20 à 200

Tableau 1: catégorisation des ondes EEG

1.3.3 EEG normal des enfants prématurés

L'interprétation de l'EEG néonatal exige une connaissance du développement normal de l'EEG à partir de l'extrême prématurité jusqu'à la naissance à terme. En général, l'activité EEG néonatale a été discutée en termes de passage d'un EEG discontinu à un EEG continu [23]. Le contexte EEG normal des extrêmes prématurités, appelé tracé discontinu (TD) [23], montre un modèle essentiellement dichotomique. Les périodes d'activité à basse tension, appelées intervalles inter-bouffées (IBI), alternent avec des périodes d'activité à haute tension et de fréquence mixte appelées bouffées. Plusieurs rythmes normaux, par ex. thêta ont été identifiés dans l'EEG prématuré, et peuvent être utiles pour l'évaluation de la maturation de l'EEG.

La distribution de fréquence discontinue de l'EEG prématuré est dominée par l'activité delta, jusqu'à 80% de fréquences en dessous de 1 Hz chez les nourrissons <32 semaines AG [24] tandis que l'activité thêta et alpha est de plus en plus reconnu chez les nourrissons à plein terme (40 semaines AG). Une corrélation entre l'âge et le pouvoir des bandes delta et thêta, respectivement, a été signalée. [25].

Dans les bouffées de l'EEG prématuré normal, l'activité rapide est superposée aux lentes ondes de grande amplitude [26]. Avec une maturation croissante, la durée des bouffées augmente progressivement et les IBI deviennent plus courtes [27].

De cette manière, l'activité dans l'EEG change graduellement vers une plus grande continuité [28]. Différentes définitions des bouffées et IBI ont été utilisées, par exemple la tension maximale du signal pendant l'IBI variait entre 15 μV et 30 μV .

Hahn et al. [29] ont montré une différence dans les valeurs IBI selon la définition des seuils qui a été utilisée. Les critères d'amplitude stricte sont spécifiques dans la mesure du dispositif d'enregistrement, des réglages du filtre et des distances des électrodes. Un résumé de référence des données montre que, dans toutes les études, la durée maximale des IBI était moins que 60 secondes, et la durée moyenne des IBI était de 6-14 secondes, chez les nourrissons en bonne santé à 25-28 semaines AG [30].

Les modifications de l'état du comportement, observées sous forme de modifications du mouvement oculaire, de la respiration, de la fréquence cardiaque, des mouvements globaux et du tonus musculaire, sont associées à des altérations de l'activité de l'EEG. À terme, le sommeil calme se caractérise par une activité lente à haute tension (tracé alternant) [31]. Le sommeil agissant et le réveil se caractérise par un EEG continu. Les états d'éveil et de sommeil sont régulés par les connexions du tronc cérébral et de l'hypothalamus du système d'activation réticulaire ascendant [32]. De cette manière, le cycle sommeil-veille tel qu'il est exprimé dans l'EEG reflète des corrélations physiologiques spécifiques de la connectivité fonctionnelle.

1.3.4 EEG anormal des enfants prématurés

Les anomalies de l'EEG prématuré peuvent être caractérisées comme des anomalies aiguës ou chroniques. Cette catégorisation de l'EEG s'est révélée très utile puisque des changements aigus de l'activité électro-corticale apparaissent après des sévères problèmes pathologiques. Les anomalies persistantes du stade chronique sont souvent des marqueurs de lésions établies [33].

Les anomalies aiguës apparaissent pendant et après un changement dans la continuité (IBI plus long et absence des activités continues), ou une fréquence plus rapides et une amplitude réduite [34]. La présence de telles caractéristiques d'EEG a été associée à des lésions cérébrales hémorragiques et ischémiques chez les nourrissons prématurés [35]. Maruyama et al. ont montré chez des nourrissons très prématurés que le degré maximal d'anomalies aiguës au cours des premiers jours postnataux était associé au risque de développement ultérieur de la paralysie cérébrale et était également corrélé avec sa sévérité [36].

Les anomalies chroniques indiquent des anomalies persistantes et caractéristiques de l'EEG apparaissant lorsque les anomalies aiguës ont disparu. Il s'agit notamment des activités désorganisées qui ont été associées à un mauvais développement neurologique chez les nourrissons très prématurés et modérés [37]. L'augmentation de l'IBI seule est difficile à attribuer à des anomalies aiguës ou chroniques car elle peut représenter soit une suppression aiguë, soit une activité immature. Des activités désorganisées sont caractérisées par des ondes anormales, par exemple ondes rolandiques positives, qui sont prédictives si elles sont fréquentes suite à une paralysie cérébrale [38].

1.3.5 Artefacts rencontrés

Les artefacts sont définis comme des phénomènes d'origine artificielle ou accidentelle, rencontrés lors d'une observation ou d'une expérience (dictionnaire Larousse, 1990). Leur présence sur les enregistrements EEG est courante. Une enquête réalisée dans le cadre du projet DREAMS, par le Docteur M. Kerkhofs de l'Hôpital Andre Vesale du roi Charles montre que sur 44 tracés de patients atteints de pathologies diverses, 22% d'entre eux présentent plus de 10% de périodes avec artefacts [39].

Parmi les principaux types d'artefacts rencontrés, citons:

- L'artefact mouvement jambe/menton sur l'EEG (73%);
- L'interférence cardiaque sur les autres signaux (11%);
- L'artefact EOG (Electro-oculogramme) sur l'EEG (2%);
- L'ondulation lente sur l'EEG (18%);
- L'artefact pointe sur l'EEG (36%);
- Les artefacts divers sur l'EEG (18%).

Pour éviter que ces artefacts interfèrent sur la classification automatique de l'EEG, il est nécessaire de les éliminer avant toute application d'extraction des caractéristiques [40].

Les méthodes de détection d'artefacts rencontrées dans la littérature sont très variées. Plusieurs d'entre elles utilisent des modèles autorégressifs adaptatifs pour repérer les changements brusques du signal EEG [41]. D'autres calculent la

corrélation existante entre deux signaux polysomnographiques pour détecter par exemple la présence d'interférence EOG sur l'EEG [42]. Quelques méthodes utilisent un opérateur d'énergie non linéaire pour en déduire un certain nombre de variables confrontées ensuite à des valeurs limites [43]. Enfin, plusieurs procédés comparent directement les amplitudes des signaux polysomnographiques à des seuils, afin de détecter les valeurs trop excessives [44].

En ce qui concerne la correction d'artefacts, le nombre des études traitant ce sujet semble être plus limité. Quelques études ont utilisé la correction des artefacts EOG sur l'EEG [45].



Figure 6: Interférence EOG sur l'EEG

La plupart des travaux rencontrés concerne surtout la correction de l'interférence cardiaque présente sur les autres signaux [46].

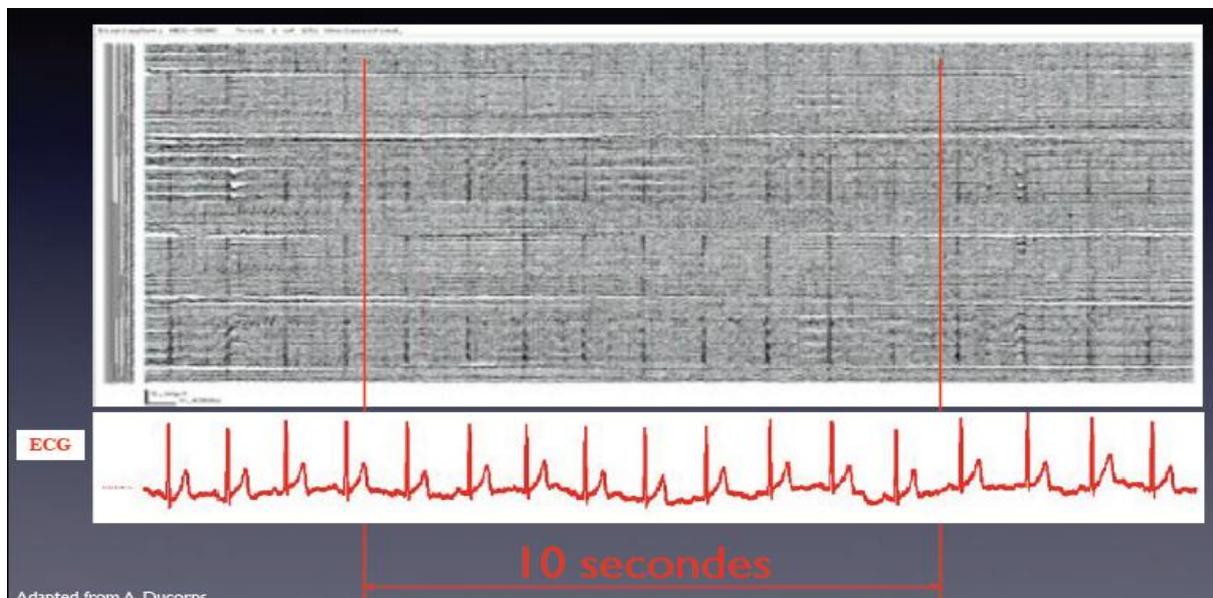


Figure 7: Interférence ECG (Electrocardiogramme) sur l'EEG

Parmi les artefacts, il y a une distinction entre ceux de courte durée n'excédant pas quelques secondes (il s'agit de la plupart des artefacts) et ceux de plus longue durée (ce sont les interférences cardiaques et les artefacts ondulations lentes) [47]. Dans le premier cas, les interférences produites sont fortement aléatoires ce qui rend difficile leur correction. Par contre, la durée qu'ils occupent au sein de l'époque à classer est généralement faible.

Dans le deuxième cas, les artefacts ne peuvent être traités de la même manière car ils occupent pratiquement toutes les époques de l'enregistrement. Il a donc été développé des procédures de correction spécifiques.

Divers procédés de détection ont été mis au point afin de couvrir les nombreuses variétés d'artefacts rencontrés. Chacun d'eux a été implémenté de manière à s'adapter aux propriétés statistiques du signal (qui peut fortement varier d'un individu à l'autre). Ainsi, les seuils utilisés sont toujours dépendants de la valeur moyenne et de l'écart type du signal considéré. Dans la suite de ce travail, l'enregistrement est divisé en période (ou époque) de 20 ou 30 secondes [48].

- **Le procédé Atf_Esat** est destiné à détecter les saturations des signaux EEG.

Son principe est de repérer les valeurs maximales et minimales du signal sur la totalité de l'enregistrement et de calculer ensuite la différence entre ces deux valeurs: $intervalle = max - min$. Puis, dès que le signal dépasse les seuils ($min + intervalle * erreur$) ou ($max - intervalle * erreur$) pendant plus de min secondes, on considère qu'il y a saturation et donc artefact.

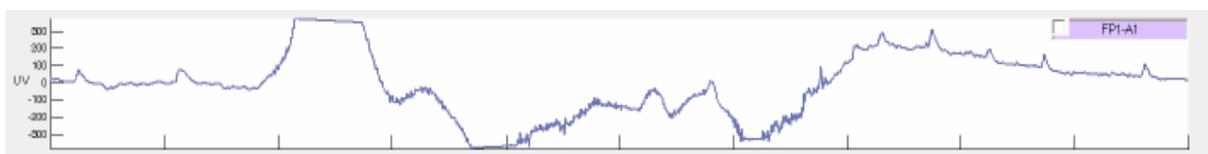


Figure 8: procédé Atf_Esat

- **Le procédé Atf_Egd** détecte les augmentations inhabituelles du signal EEG. Son principe est de calculer la moyenne et l'écart-type de l'EEG sur les 5 époques entourant l'époque courante, et dès que le signal dépasse la valeur $seuil = moyennes + threshold * écart-types$, on considère qu'il y a un artefact.

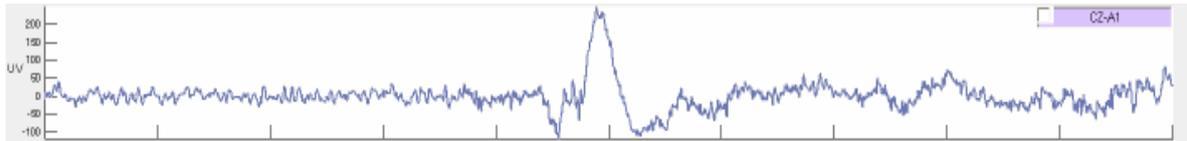


Figure 9: procédé Atf_Egd

- **Le procédé Atf_noE** permet de repérer les valeurs constantes des signaux EEG. Son principe est de calculer tout d'abord l'écart-type sur la totalité de l'enregistrement. Ensuite les tranches d'analyse sont examinées séparément. Si l'écart entre le maximum et le minimum du signal dans une tranche est supérieur à $threshold * \text{écart-type}$, on considère qu'il y a un artefact.

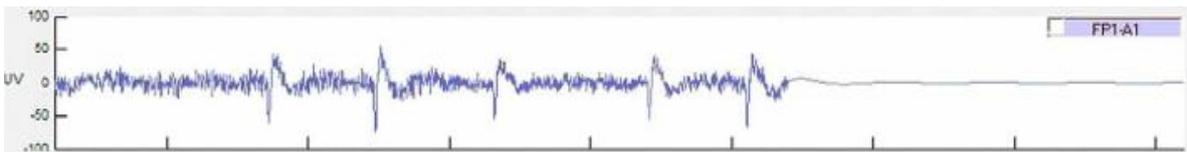


Figure 10: procédé Atf_noE

- **Le procédé Atf_trans** permet de détecter les transitions brusques du signal EEG telles que les artefacts pointes. Son principe est de calculer la moyenne et l'écart-type du signal EEG sur les 5 époques entourant l'époque courante, et dès que la différence maximale du potentiel présente en delta secondes est supérieure au $seuil = moyennes + threshold * \text{écart types}$, on considère qu'il y a un artefact.



Figure 11: Le procédé Atf_trans

1.4 Méthodes de prévision du devenir du nouveau-né prématuré

L'identification du risque neuro-développemental à la naissance peut aider à utiliser des services d'intervention précoce, ce qui facilite le traitement. L'intervention périnatale pour les bébés prématurés qui ont un risque d'avoir des problèmes tardifs sert à réduire à long terme la prévention des lésions cérébrales et le développement anormal du cerveau. Plusieurs méthodes ont été utilisées pour prévoir ce risque dès la naissance.

1.4.1 Analyse d'image obtenue par Imagerie à Résonance Magnétique

L'imagerie à résonance magnétique (IRM) pendant la période néonatale à terme équivalent (âge gestationnel de 40 semaines) est un outil pour aider à identifier

l'évaluation pronostique précoce du nourrisson prématuré. Elle est de plus en plus utilisée pour identifier les lésions de la substance blanche cérébrale dans le cerveau des nourrissons prématurés à un âge équivalent à celui du terme. La présence d'anomalie de la substance blanche modérée ou sévère sur l'IRM réalisée autour de l'âge équivalent à terme peut prédire la paralysie cérébrale. Au cours de la dernière décennie, l'utilisation de l'IRM comme outil de dépistage chez les nouveau-nés prématurés et à faible poids de naissance a été un sujet d'intérêt majeur et plusieurs études ont été publiées sur son utilisation [49 - 50]. Il est annoncé comme un outil précieux pour prévoir les risques sur le développement neurodéveloppemental chez les nouveau-nés très prématurés, et son utilisation clinique est donc utile [51].

Les études sur l'IRM néonatales ont indiqué que la majorité des enfants très prématurés ont des anomalies de la substance blanche et de la substance grise. De telles anomalies ont été trouvées comme très corrélées avec les troubles neurologiques.

Lianne Woodward et al. [52] ont étudié 167 nourrissons très prématurés (âge gestationnel à la naissance, 30 semaines ou moins) pour évaluer les associations entre les anomalies de la substance blanche qualitativement présentes dans l'IRM à terme équivalent et les risques d'un retard cognitif, un retard psychomoteur sévère, une paralysie cérébrale et une névrose visuelle 2 ans après la naissance. Chaque enfant a subi un traitement neurologique pour évaluer la qualité de la capacité motrice, la coordination, la démarche, le comportement et la paralysie cérébrale. Enfin, les évaluations de la vision et de l'audition ont été complétées par un ophtalmologiste et audiologiste, respectivement.

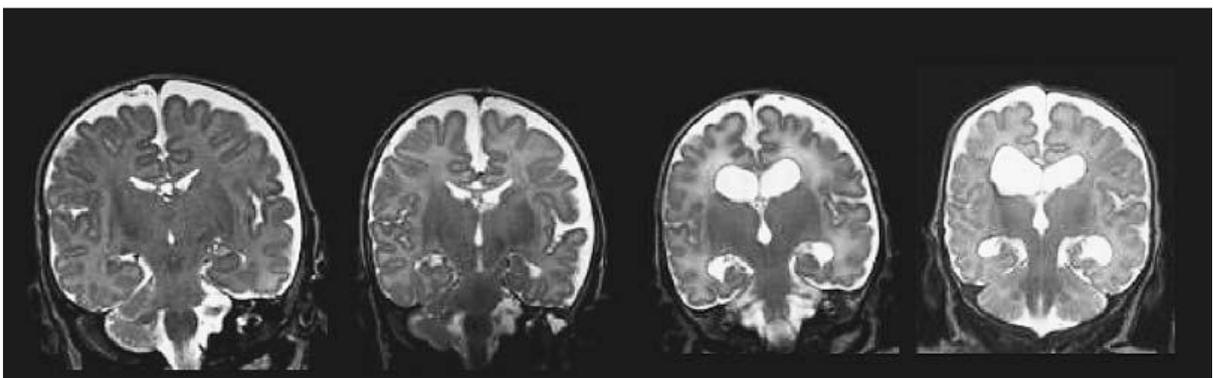


Figure 12: substance blanche dans l'IRM

Dans l'IRM à terme équivalent, 47 nourrissons (28 %) n'avaient aucune anomalie de la substance blanche, alors que 85 nourrissons (51%) présentaient des anomalies légères, 29 (17 %) avaient des anomalies moyennes et 6 (4 %) avaient des anomalies sévères. D'autre part, 82 nourrissons (49%) présentaient des anomalies de la substance grise. La gravité des anomalies de la substance blanche était fortement corrélée avec la présence de substance grise. À l'âge de deux ans, 164 enfants ont été évalués; 1 enfant était aveugle, et 2 enfants ont été exclus car les données disponibles étaient insuffisantes, 87 (53 %) avaient un développement mental satisfaisant, 50 enfants (30%) avaient un retard moyen, et 27 (17%) avaient un retard sévère. D'autre part, 103 des 164 enfants testés (63%) avaient un développement psychomoteur normal, 44 enfants (27 %) avaient un léger retard, et 17 enfants (10%) avaient un retard psychomoteur sévère. Parmi les 167 enfants, 17 enfants (10%) avaient une paralysie cérébrale (7 légère, 4 modérées, et 6 graves), 9 enfants (5%) avaient un défaut auditif, et 12 (7%) avaient un défaut visuel (1 enfant était aveugle). Parmi les enfants ayant une paralysie cérébrale, 9 enfants ont présenté un retard psychomoteur sévère.

Ces résultats montrent que l'augmentation des anomalies de la substance blanche dans l'IRM à terme équivalent était associée à une performance plus faible du développement mental et psychomoteur 2 ans après la naissance. La présence des anomalies sévères de la substance blanche étaient prédictives à un retard du développement global et à une paralysie cérébrale.

Cependant, il est important de noter qu'une proportion importante des enfants ayant des anomalies dans la substance blanche modérée n'avait pas de déficience grave à deux ans. Bien qu'un suivi à plus long terme de ces enfants soit nécessaire, cette découverte souligne le fait que les résultats inquiétants de l'IRM n'entraînent pas nécessairement de graves problèmes. D'autre part, aucun traitement spécifique n'est disponible pour répondre aux besoins des nourrissons ayant des anomalies dans la substance blanche dans l'IRM.

Donc, l'utilisation des résultats IRM peut aider à prendre des décisions pour utiliser des programmes de suivi spécifiques, c'est-à-dire offrir des programmes d'intervention précoce (physiothérapie ou orthophonie). De plus, les résultats IRM

disponibles peuvent aider les parents d'enfants prématurés à mieux se préparer à l'avenir.

1.4.2 Analyse du signal EEG

L'électroencéphalogramme (EEG) peut présenter l'une des meilleures méthodes de prévision de l'état neurologique anormal du nouveau-né prématuré [53]. L'EEG étant un signal qui mesure l'activité électrique du cerveau correspondant à une sommation des courants générés dans les neurones [54], il est important pour le diagnostic du mouvement et de l'état neurologique anormal (apnée, rougeur du visage, léthargie ou hyperactivité) [55]. Du point de vue médical, Un EEG, dans les 24 premières heures de vie, comprend plusieurs caractéristiques qui peuvent avoir une valeur prédictive positive de 94% pour l'état normal. En revanche, un EEG très anormal ou inactif prédit la mort dans la grande majorité des cas. Les anomalies modérées seront associées à un handicap neurologique dans 60% des cas [56].

Un signal EEG est généralement formé des intervalles bouffées (activité) et interbouffées (aplatissement ou IBI – *InterBurst Interval*) selon l'activité électrique du cerveau. Dans la littérature, plusieurs définitions pour les IBI ont été présentées. Un IBI est considéré comme une période d'aplatissement de plus de 3 secondes avec une tension inférieure à $10\mu\text{V}$ présente dans plus de 50% de l'enregistrement EEG [57]. Dans les cas de nourrissons à terme, l'EEG a été classé: continu, un peu continu ou discontinu avec amplitude inférieure à $5\mu\text{V}$ ou plat [58]. Il a été montré que la durée du plus long IBI dans l'EEG est fortement corrélée avec une évolution anormale du cerveau [59]. Ainsi, l'IBI est un marqueur très prometteur pour le calcul d'indices de risque sur le devenir de l'enfant. L'amplitude de l'électroencéphalographie est aujourd'hui une technologie couramment utilisée en néonatalogie pour la surveillance de l'activité électrique cérébrale [60] par rapport à la pathologie du cerveau. Son avantage est dû à la simplicité de l'interprétation. En néonatal, l'amplitude de l'EEG est une méthode très utile pour qualifier le développement neurologique de l'activité du cerveau. Un certain nombre de recherches ont étudié l'influence de l'amplitude sur le pronostic des nouveau-nés prématurés et des nouveau-nés à terme [61]. La continuité est apparue à 30 semaines et a augmenté avec l'âge. Une corrélation a été confirmée entre un EEG continu et l'âge gestationnel pour les nouveau-nés prématurés normaux [62]. La

durée de la plus longue période d'aplatissement diminue lorsque l'âge gestationnel augmente.

Dans une revue de 691 EEG effectués sur 270 nouveau-nés, pour la plupart des nés à terme et enregistrés dans le premier mois, Menache et al. [63] ont montré que l'EEG normal (tension >25 μ V) est fortement corrélé avec un résultat favorable du développement neurologique de l'enfant. Par contre, une durée des IBI (tension <10 μ V) de plus de 30 secondes est corrélé avec la présence à la fois du résultat neurologique défavorable et d'une l'épilepsie ultérieure, ce qui suggère que la durée de l'IBI est un paramètre qui pourrait être utile pour l'estimation rapide du pronostic neurologique chez les patients. Selon cette étude, un enfant dont l'EEG contient une durée d'IBI prédominante de plus de 30 secondes a une très grande chance de décès neurologiques graves et une probabilité de 86% de développer une épilepsie.

Chez le nouveau-né prématuré l'EEG a la particularité d'être physiologiquement discontinu (alternance de bouffés et d'IBI), mais cette discontinuité évolue très rapidement au cours de la période de prématurité de 26 à 37 semaines [64]. La durée de la plus longue période d'aplatissement a atteint 3min entre 24 et 27 semaines. Il a diminué à 88 secondes entre 27 et 29 semaines. Les changements rapides ont eu lieu entre 26 et 29 semaines, et plus lents entre 29 et 38 semaines. Par conséquent, la discontinuité est normale pour certains âges gestationnels, mais peut être anormale pour les autres.

<u>Age gestationnel</u>	<u>EEG</u>
26 semaines	Discontinu (calme/agité)
28 semaines	Discontinu(>40s)/continu
30 semaines	Discontinu(<20s)/continu
32 semaines	Discontinu(<15s)/continu
34 semaines	Discontinu(<10s)/continu
36 semaines	Discontinu(<10s)/continu
38 semaines	Semi discontinu, alternant/continu
40 semaines	Alternant /continu

Figure 13: durée de l'IBI normal en fonction de l'AG

1.5 Modèles de classification automatique

Les modèles de classification automatique sont des systèmes qui consistent à prévoir un état (généralement décrit par une variable discrète) au moyen d'une analyse de grandes quantités de données stockées au cours des années d'exploitation. Ces données sont utilisées par des techniques d'apprentissage (*Machine Learning*) pour extraire des connaissances très précieuses. Par suite, l'apprentissage utilisant des modèles de classification est un type d'intelligence artificielle qui peut jouer un rôle essentiel dans l'exploration des données [65]. Il est utilisé dans le développement des programmes informatiques qui utilisent des informations ayant des entrées et des sorties, pour apprendre et créer une fonction automatique qui déduit les sorties en fonction des entrées. La fonction créée peut être appliquée sur de nouvelles données, afin de spécifier leur sortie. Elle peut être utilisée pour prévoir l'avenir en fonction du passé. Dans la littérature, il existe un très grand nombre de modèles de classification dont l'adéquation dépend de l'application à traiter. Dans la suite, nous allons introduire certains modèles parmi les plus populaires, à partir desquels nous allons choisir ceux qui nous paraissent les plus intéressants dans l'apprentissage sur notre ensemble de données.

1.5.1 Régression linéaire multiple (MLR)

La régression linéaire (ou en anglais Multiple Linear regression MLR) est une approche utilisée pour modéliser la relation entre une variable dépendante scalaire Y et une ou plusieurs variables explicatives (ou variables indépendantes) notées X [66]. Le cas d'une seule variable explicative s'appelle une régression linéaire simple.

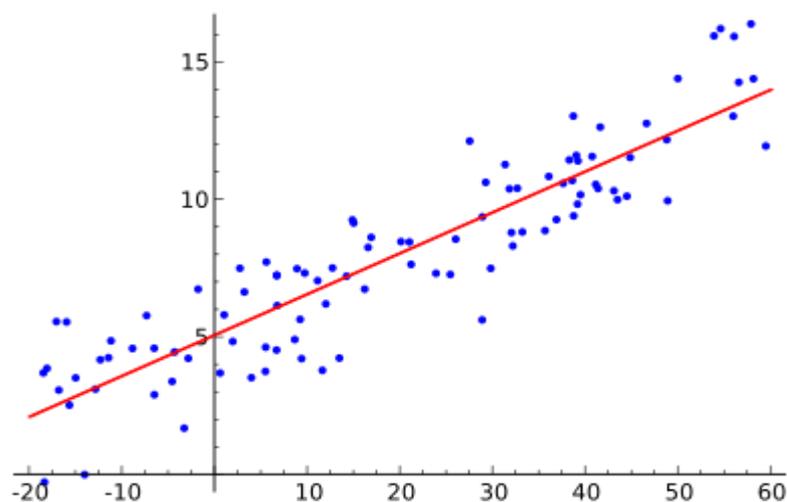


Figure 14: Régression linéaire simple

Pour plus d'une variable explicative, c'est-à-dire s'il y a une relation entre un nombre de variables X_1, \dots, X_p et une variable Y , le processus s'appelle une régression linéaire multiple.

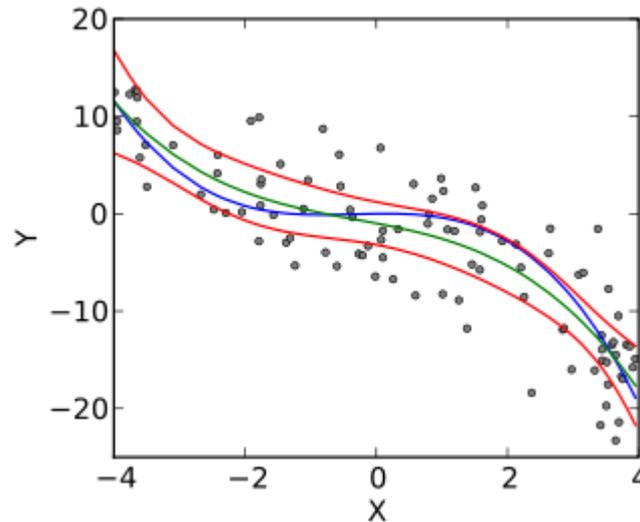


Figure 15: Régression linéaire multiple.

En régression linéaire, les relations sont modélisées à l'aide de fonctions prédictives linéaires dont les paramètres inconnus sont estimés à partir des données. La moyenne conditionnelle de Y sachant la valeur de X est supposée être une fonction de X . Comme toutes les formes d'analyse de régression, la régression linéaire se concentre sur la distribution de probabilité conditionnelle de Y sachant X plutôt que sur la distribution de probabilité conjointe de Y et X , qui est le domaine de l'analyse multi-variée. La régression linéaire a été le premier type de modèle de régression à être étudié et à être largement utilisé dans des applications pratiques [67]. C'est parce que les modèles qui dépendent linéairement de leurs paramètres inconnus sont plus faciles à adapter que les modèles qui ne sont pas linéairement liés à leurs paramètres et parce que les propriétés statistiques des estimateurs résultants sont plus faciles à déterminer.

La régression linéaire comporte de nombreuses utilisations pratiques. Elle peut être utilisée pour adapter un modèle prédictif à un ensemble de données observées de valeurs Y et X . Après avoir développé un tel modèle, si une valeur supplémentaire de X est alors donnée, le modèle peut être utilisé pour faire une prédiction de la valeur de Y . La plupart des applications appartiennent à l'une des deux grandes catégories suivantes:

- S'il y a une relation entre un nombre de variables X_1, \dots, X_p et une variable Y , alors que les variables X_i sont indépendantes entre elles, dans ce cas l'exactitude de la prédiction de Y en fonction des variables X_i ne contient pas des informations redondantes.
- S'il y a une relation entre un nombre de variables X_1, \dots, X_p et une variable Y , alors que les variables X_i sont dépendantes entre elles, dans ce cas les sous-ensembles de X_j contenant des informations redondantes sur Y peuvent avoir une influence négative sur l'exactitude de la prédiction de Y en fonction des variables X_i .

Soit l'exemple pratique suivant:

On suppose que le salaire d'un employé dans une entreprise est déterminé en fonction des critères suivants:

- Combien de temps l'employé a travaillé pour l'entreprise (ancienneté).
- L'âge de l'employé (l'âge a une relation avec l'expérience).
- Le type du travail qu'il fait.

La relation entre le salaire et l'âge d'une personne indique comment deux variables sont liées l'une à l'autre.

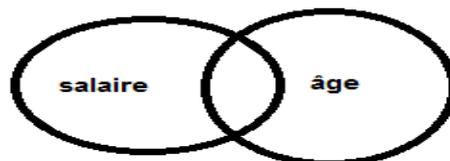


Figure 16: Exemple d'application à deux variables dépendantes

La relation entre le type de travail avec le salaire d'une part et l'âge avec le salaire d'autre part indique comment deux variables indépendantes sont liées à une variable dépendante alors que les deux variables indépendantes ne sont pas liées l'une à l'autre.



Figure 17: Exemple d'application à 3 variables dont 2 sont indépendantes liées à une troisième dépendante

La relation entre l'âge avec le salaire d'une part et l'ancienneté avec le salaire d'autre part indique comment deux variables indépendantes sont liées à une variable dépendante, tandis que les deux variables indépendantes sont liées l'une à l'autre. Donc, lorsqu'on a plus d'une variable indépendante et que ces variables ne sont pas liées l'une à l'autre, on peut très bien faire des prédictions plus précises sur notre variable dépendante. Une fois qu'on veut identifier comment ces variables multiples se rapportent à notre variable dépendante, on peut prendre des informations sur toutes les variables indépendantes et l'utiliser pour faire des prévisions beaucoup plus puissantes et précises. Ce dernier processus s'appelle "Régression multiple". Il permet d'examiner comment les variables indépendantes multiples sont liées à une variable dépendante

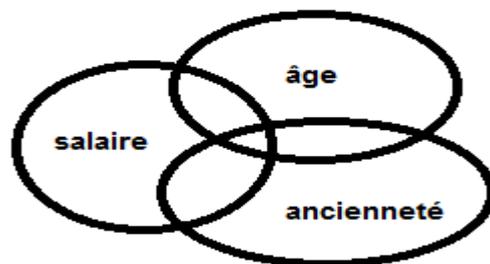


Figure 18: Exemple d'application à 3 variables dont 2 sont dépendantes liées à une troisième dépendante

On remarque dans cet exemple que le salaire dépend du type du travail, de l'âge et de l'ancienneté, par suite ils sont 3 variables explicatives pour le salaire. Cependant, l'âge et l'ancienneté sont 2 variables dépendantes, c'est-à-dire qu'ils contiennent des informations redondantes sur le salaire, tandis que le type du travail et l'âge sont 2 variables indépendantes. Dans ce cas, la prédiction du salaire en fonction du type du travail et de l'âge peut donner un meilleur résultat que celui de la prévision du salaire en fonction de l'âge et de l'ancienneté puisqu'ils contiennent des informations redondantes sur le salaire.

1.5.2 Analyse discriminante linéaire (LDA)

L'analyse discriminante linéaire (ou en anglais Linear discriminant Analysis - LDA) est une technique de transformation linéaire qui est couramment utilisée pour la réduction de la dimensionnalité dans l'étape de prétraitement pour la classification des modèles et les applications d'apprentissage par machine [68]. L'objectif est de projeter un ensemble de données sur un espace de dimension inférieure avec une bonne séparabilité de classe afin de réduire les coûts de calcul

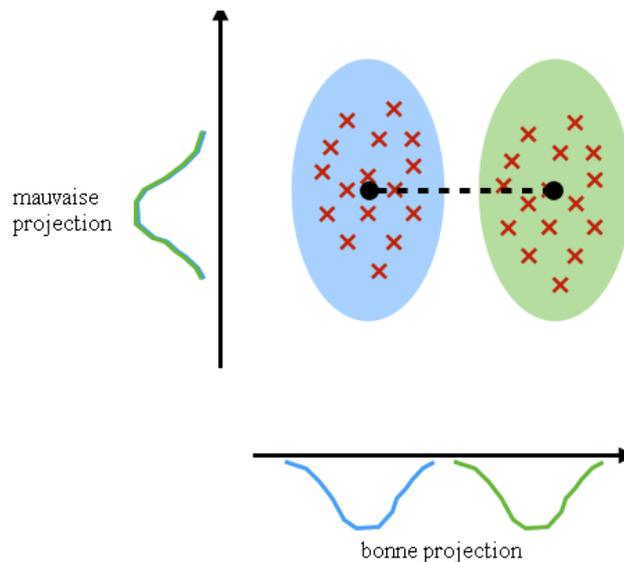


Figure 19: projection sur un axe pour réduire la dimension

L'analyse discriminante linéaire a été décrite initialement par Ronald A. Fisher en 1936 pour un problème de 2 classes, puis elle a ensuite été généralisée comme «Analyse discriminante linéaire multi-classe» ou «Analyse discriminante multiple» par C. R. Rao en 1948.

Les 5 étapes caractérisant l'analyse discriminante linéaire se résument comme suit:

1. Estimer les moyennes d -dimensionnelle pour les différentes classes à partir de l'ensemble de données.
2. Calculer les matrices de dispersion intra-classes et inter-classes.
3. Calculer les vecteurs propres (e_1, e_2, \dots, e_d) et les valeurs propres correspondantes $(\lambda_1, \lambda_2, \dots, \lambda_d)$ pour les matrices de dispersion.
4. Trier les vecteurs propres par ordre de valeurs propres décroissantes et choisir les k premiers vecteurs propres correspondants pour construire une matrice W de dimension $d \times k$
5. Utiliser cette matrice de vecteurs propres pour transformer les échantillons sur le nouveau sous-espace. Ceci peut être résumé par la multiplication matricielle: $Y = X \times W$ (où X est une matrice $n \times d$ représentant les n observations, et Y est l'échantillon de taille $n \times k$ transformés dans le nouveau sous-espace).

En utilisant la fonction de distribution gaussienne et en simplifiant, nous finissons avec l'équation ci-dessous. C'est ce qu'on appelle une fonction discriminante dont la valeur maximale détermine la classe de sortie (Y):

$$D_k(x) = x' \Sigma^{-1} \mu_k - \frac{1}{2} \mu_k' \Sigma^{-1} \mu_k + \ln \pi_k$$

$D_k(x)$ est la fonction de discrimination pour la classe k étant donnée x , μ_k , Σ^{-1} et π_k sont tous estimés à partir des données.

1.5.3 Machines à vecteurs de support (SVM)

Les Machines à vecteurs de support (ou en anglais Support Vector Machine ou SVM) sont des modèles d'apprentissage supervisés avec des algorithmes qui analysent les données utilisées pour les classifier. A l'origine, les SVM sont conçus pour répondre au problème de classification binaire et permettent de construire un classifieur linéaire non probabiliste. Un SVM effectue la classification en construisant un hyperplan N-dimensionnel qui sépare de manière optimale les données en deux catégories [69]. Les modèles SVM sont un ami proche des réseaux de neurones de type perceptron multicouches classiques. En utilisant une fonction de noyau, les SVM sont une méthode d'apprentissage alternative pour la fonction polynomiale, la fonction radiale et les classificateurs de perceptron multicouches dans lesquels les poids du réseau se trouvent en résolvant un problème de programmation quadratique avec des contraintes linéaires plutôt que par résolution d'un problème de minimisation de l'erreur comme dans l'apprentissage standard du réseau de neurones.

Examinons un simple exemple bidimensionnel. Supposons que nous souhaitons effectuer une classification, et nos données ont une variable cible catégorielle avec deux catégories. Supposons également qu'il existe deux variables prédictives avec des valeurs continues. Si nous traçons les points de données en utilisant la valeur d'un prédicteur sur l'axe des X et l'autre sur l'axe des Y, nous pourrions finir avec une image telle qu'illustrée ci-dessous. Une catégorie de la variable cible est représentée par des rectangles tandis que l'autre catégorie est représentée par des ovales.

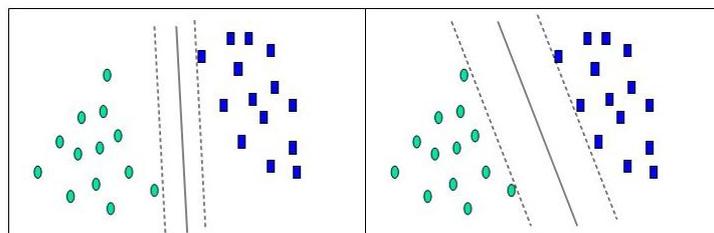


Figure 20: hyperplan 1-dimensionnel qui sépare les cas en fonction de leurs catégories

Dans cet exemple idéal, les points d'une catégorie sont dans le coin inférieur gauche et les points de l'autre catégorie sont dans le coin supérieur droit; Les points sont complètement séparés. L'analyse SVM tente de trouver un hyperplan 1-dimensionnel (c'est-à-dire une ligne) qui sépare les points en fonction de leurs catégories cibles. Il existe un nombre infini de droites possibles; deux droites candidates sont indiquées ci-dessus. La question est de savoir quelle droite est la meilleure et comment définir la droite « optimale ».

Les lignes pointillées dessinées parallèlement à la droite de séparation marquent la distance entre la droite de séparation et les vecteurs les plus proches de cette droite. La distance entre les lignes pointillées s'appelle la marge. Les vecteurs (points) qui limitent la largeur de la marge sont les vecteurs supports. Ceci est illustré par la figure suivante:

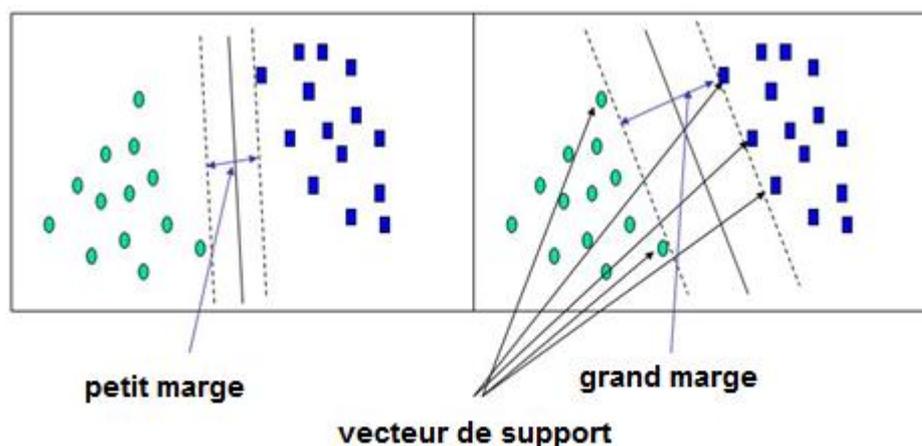


Figure 21: marge optimisée entre les vecteurs supports

Une analyse SVM trouve la droite (ou, en général, l'hyperplan) orientée de sorte que la marge entre les vecteurs supports soit optimisée. Dans la figure ci-dessus, la marge du panneau droit est supérieure à la marge dans le panneau de gauche.

Malheureusement, toutes les analyses ne se composent pas de variables cibles à deux catégories avec deux variables prédictives, et le groupe de points pourrait être divisé par une autre courbe qu'une droite. Donc un SVM doit traiter:

- plus de deux variables prédictives,
- séparer les points par des courbes non linéaires,
- traiter les cas où les grappes ne peuvent pas être complètement séparées, et

- gérer les classifications avec plus de deux catégories.

Si nous avons trois variables prédictives, nous pouvons tracer les points dans un cube tridimensionnel. Les points sur un plan bidimensionnel peuvent être séparés par une ligne à 1 dimension. De même, les points d'un cube tridimensionnel peuvent être séparés par un plan bidimensionnel

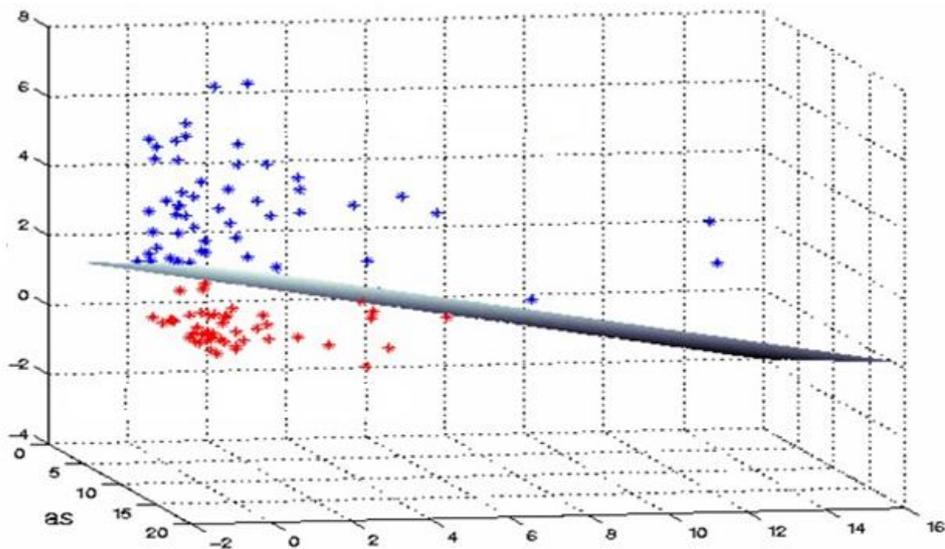


Figure 22: Points d'un cube tridimensionnel séparés par un plan bidimensionnel

Lorsque nous ajoutons des variables prédictives supplémentaires (attributs), les points de données peuvent être représentés dans l'espace N-dimensionnel, et un hyperplan numérique (N-1) peut les séparer.

Le moyen le plus simple de diviser deux groupes est celui d'une ligne droite, d'un plan plat ou d'un hyper-plan N-dimensionnel. Mais que faire si les points sont séparés par une région non linéaire telle qu'indiquée ci-dessous?

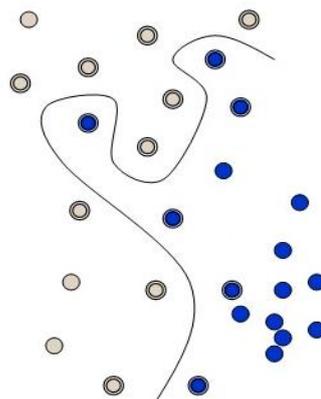


Figure 23: points séparés par une région non linéaire

Dans ce cas, nous avons besoin d'une ligne de division non linéaire. Plutôt que d'ajuster les courbes non linéaires aux données, SVM gère cela en utilisant une fonction Kernel pour distribuer les données dans un espace différent où un hyperplan peut être utilisé pour effectuer la séparation.

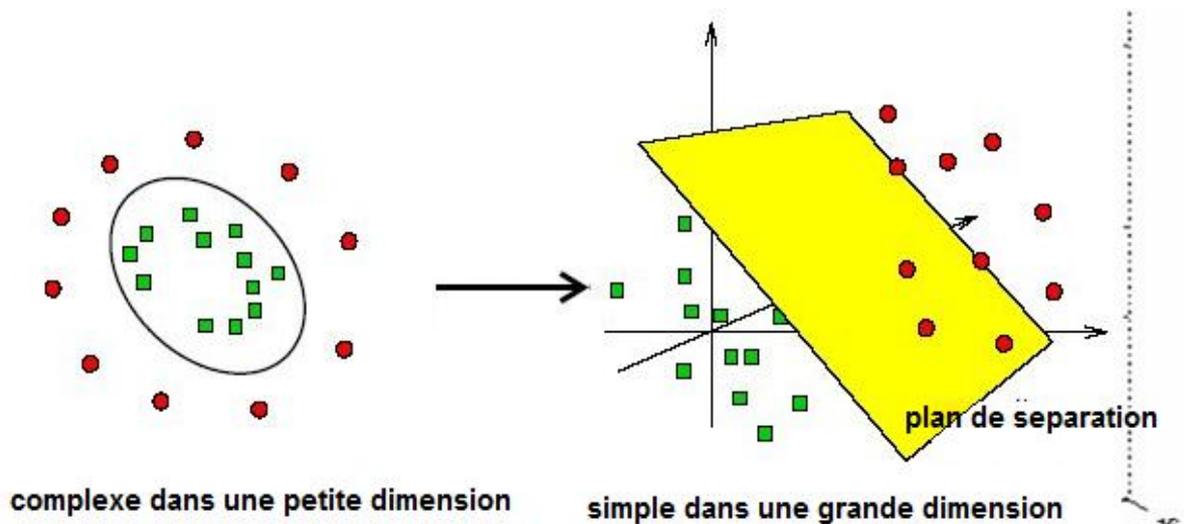


Figure 24: Séparations avec des limites très complexes

Le concept d'une fonction de Kernel map est très puissant. Il permet aux modèles SVM d'effectuer des séparations même avec des limites très complexes telles que celles ci-dessus.

1.5.4 Arbre de décision (DT)

L'apprentissage dans les arbres de décision (ou en anglais Decision Tree - DT) est une méthode couramment utilisée dans l'exploration de données. L'objectif est de créer un modèle qui prédit la valeur d'une variable de sortie en fonction de plusieurs variables d'entrée. Chaque nœud intérieur correspond à l'une des variables d'entrée. Chaque feuille représente une valeur de la variable sortie compte tenu des valeurs des variables d'entrée représentées par le chemin de la racine à la feuille.

Un arbre peut être «appris» en divisant la source définie en sous-ensembles en fonction d'un test de valeur d'attribut. Ce processus est répété sur chaque sous-ensemble dérivé de manière récursive appelée partition récursive. La récurrence est terminée lorsque le sous-ensemble d'une source n'ajoute plus de valeur. Dans l'exploration de données, les arbres de décision peuvent également être décrits

comme la combinaison de techniques mathématiques et de calcul pour faciliter la description, la catégorisation et la généralisation d'un ensemble de données.

Les données sont fournies par des enregistrements de la forme:

$$(X, Y) = (X_1, X_2, \dots, X_k, Y)$$

La variable dépendante, Y , est la variable cible que nous essayons de comprendre, de classer ou de généraliser. Le vecteur X est composé des variables d'entrée, X_1, X_2, \dots, X_k , qui sont utilisées pour cette tâche.

Un arbre de décision est une structure de diagramme de flux, où chaque nœud interne (non-feuille) désigne un test sur un attribut, chaque branche représente le résultat d'un test et chaque nœud (ou terminal) possède une étiquette de classe. Le nœud le plus haut d'un arbre est le nœud racine

Dans l'apprentissage des arbres de décision, ID3 (Itérative Dichotomiser 3) est un algorithme inventé par Ross Quinlan [70] utilisé pour générer un arbre de décision à partir d'un ensemble de données.

L'algorithme ID3 commence avec l'ensemble d'origine S comme nœud racine. Sur chaque itération de l'algorithme, il itère à travers tous les attributs non utilisés de l'ensemble S et calcule l'entropie $H(S)$ (ou le gain d'information $GI(S)$) de cet attribut. Il sélectionne ensuite l'attribut qui a la plus petite entropie (ou le plus grand gain d'information). L'ensemble S est ensuite divisé en sous-ensemble contenant les attributs sélectionnés.

La récurrence sur un sous-ensemble peut s'arrêter dans l'un de ces cas:

- chaque élément du sous-ensemble appartient à la même classe, puis le nœud est transformé en feuille et étiqueté avec la classe des exemples ;
- il n'y a plus d'attributs à sélectionner, mais les exemples n'appartiennent toujours pas à la même classe (certains sont + et certains sont -), alors le nœud est transformé en feuille et étiqueté avec la classe la plus courante des exemples dans le sous-ensemble ;

- il n'y a pas d'exemples dans le sous-ensemble, cela se produit lorsqu'aucun exemple dans l'ensemble parent n'a été trouvé correspondant à une valeur spécifique de l'attribut sélectionné.

L'entropie est définie comme ci-dessous :

$$H(T) = IE(P_1, P_2, \dots, P_n) = - \sum_{i=1}^j P_i \log_2(P_i)$$

Où P_1, P_2, \dots, P_n sont des fractions qui représentent le pourcentage de chaque classe présente dans le nœud enfant résultant d'une division dans l'arbre.

Gain d'information = Entropie (parent) - Somme pondérée de l'entropie (enfants)

Le gain d'informations est utilisé pour décider le choix de division à chaque étape de la construction de l'arbre. Par soucis de simplicité et de lisibilité de l'arbre, nous voulons garder notre arbre petit. Pour ce faire, à chaque étape, nous devrions choisir la division qui se traduit par les nœuds les plus « purs ». Une mesure de pureté couramment utilisée est une valeur d'information, mesurée en bits. Pour chaque nœud de l'arbre, la valeur d'information représente la quantité d'informations attendue qui serait nécessaire pour spécifier si une nouvelle instance devrait être classée oui ou non, étant donné que l'exemple a atteint ce nœud.

Par exemple, supposons que nous travaillons avec un ensemble d'exemples, $S = \{S_1, S_2, S_3, S_4\}$ catégorisés de manière binaire (positif / négatif), de sorte que S_1 soit positif et le reste soit négatif. Supposons en outre que nous voulons calculer le gain d'information d'un attribut A , et que A peut prendre les valeurs $\{V_1, V_2, V_3, V_4\}$.

Pour calculer le gain d'information pour A par rapport à S , nous devons d'abord calculer l'entropie de S . Pour utiliser notre formule pour les catégorisations binaires, nous devons connaître la proportion de positifs et négatifs dans S , qui sont les suivantes:

$$P_+ = \frac{1}{4} \text{ et } P_- = \frac{3}{4}$$

Nous pouvons donc calculer:

$$\text{Entropie}(S) = -\frac{1}{4}\log_2\left(\frac{1}{4}\right) - \frac{3}{4}\log_2\left(\frac{3}{4}\right) = -\frac{1}{4}(-2) - \frac{3}{4}(-0,415) = 0,5 + 0,311 = 0,811$$

Ensuite, nous devons calculer l'Entropie pondéré (S_v) pour chaque valeur $v = v_1, v_2, v_3$ et v_4 , notant que la pondération implique de multiplier par $\frac{|Sv_i|}{|S|}$. S_v étant l'ensemble d'exemples de S qui ont la valeur v pour l'attribut A . Cela signifie que:

$$Sv_1 = \{S_4\}, Sv_2 = \{S_1, S_2\}, Sv_3 = \{S_3\}$$

Nous avons maintenant besoin de procéder à ces calculs:

$$\begin{aligned} \frac{|Sv_1|}{|S|} \times \text{Entropie}(Sv_1) &= \frac{1}{4} \times \left(-\left(\frac{0}{1}\right)\log_2\left(\frac{0}{1}\right) - \left(\frac{1}{1}\right)\log_2\left(\frac{1}{1}\right) \right) \\ &= \frac{1}{4} \times (-0 - (1)\log_2(1)) \\ &= \frac{1}{4} \times (-0 - 0) \\ &= 0 \end{aligned}$$

$$\begin{aligned} \frac{|Sv_2|}{|S|} \times \text{Entropie}(Sv_2) &= \frac{2}{4} \times \left(-\left(\frac{1}{2}\right)\log_2\left(\frac{1}{2}\right) - \left(\frac{1}{2}\right)\log_2\left(\frac{1}{2}\right) \right) \\ &= \frac{1}{2} \times \left(-\frac{1}{2} \times (-1) - \frac{1}{2} \times (-1) \right) \\ &= \frac{1}{2} \times (1) \\ &= \frac{1}{2} \end{aligned}$$

$$\begin{aligned} \frac{|Sv_3|}{|S|} \times \text{Entropie}(Sv_3) &= \frac{1}{4} \times \left(-\left(\frac{0}{1}\right)\log_2\left(\frac{0}{1}\right) - \left(\frac{1}{1}\right)\log_2\left(\frac{1}{1}\right) \right) \\ &= \frac{1}{4} \times (-0 - (1)\log_2(1)) \\ &= \frac{1}{4} \times (-0 - 0) = 0 \end{aligned}$$

Nous devons maintenant ajouter ces trois valeurs ensemble et tirer le résultat de notre calcul de l'entropie (S) pour nous donner le résultat final:

$$Gain(S, A) = 0,811 - \left(0 + \frac{1}{2} + 0\right) = 0,311$$

Avantages de l'arbre de décision

Parmi les autres méthodes d'exploration de données, les arbres de décision présentent divers avantages:

- Les arbres de décisions peuvent être affichés graphiquement d'une manière qui facilite l'interprétation par les non-experts. [71]
- Ils sont capables d'intégrer variables qualitatives et quantitatives. D'autres techniques sont généralement spécialisées dans l'analyse des ensembles de données qui n'ont qu'un seul type de variable. (Par exemple, les règles de relation ne peuvent être utilisées qu'avec des variables nominales alors que les réseaux de neurones peuvent être utilisés uniquement avec des variables numériques ou catégoriques binarisées).
- Nécessite peu de préparation de données. D'autres techniques exigent souvent la normalisation des données. Puisque les arbres peuvent gérer des prédicteurs qualitatifs, il n'est pas nécessaire de créer des variables fictives.
- Utilise un modèle de boîte blanche. Si une situation donnée est observable dans un modèle, l'explication de la condition s'explique facilement par une logique booléenne. En revanche, dans un modèle de boîte noire, l'explication des résultats est généralement difficile à comprendre, par exemple avec un réseau de neurones artificiel.
- Possibilité de valider un modèle à l'aide de tests statistiques. Cela permet de rendre compte de la fiabilité du modèle.
- Approche non statistique qui ne fait aucune hypothèse des données de formation ou des résidus de prédiction; Par exemple, aucune hypothèse de répartition, d'indépendance ou de variance constante.

- Fonctionne bien avec les grands ensembles de données. De grandes quantités de données peuvent être analysées à l'aide de ressources informatiques standard dans un délai raisonnable.
- Facilite la prise de décision humaine. Cela pourrait être utile lors de la modélisation des décisions / comportements humains.

Limites de l'utilisation :

- Les arbres de décision ne tendent pas à être aussi précis que d'autres approches. [72]
- Un petit changement dans les données dans l'arbre de décision peut entraîner un grand changement dans l'arbre et donc un grand changement dans les prédictions finales. [73]

1.5.5 Réseaux de neurones artificiels (ANN)

Les ANN (pour *Artificial Neural Network*) sont basés sur l'idée d'imiter le fonctionnement d'un système nerveux en établissant des bonnes connexions, pour construire un réseau de neurones artificiel. Le cerveau humain est composé d'environ 100 milliards de cellules nerveuses appelées neurones [75]. Ils sont connectés à d'autres milliers de cellules par les axones. Les entrées des organes sensoriels provenant de l'environnement externe sont acceptées par les dendrites. Ces entrées créent des impulsions électriques, qui traversent rapidement le réseau neuronal. Un neurone peut alors envoyer le message à un autre neurone et ainsi de suite.

Les ANN sont composés de plusieurs nœuds appelés neurones qui imitent les neurones biologiques. Les neurones sont connectés par des liens et ils interagissent les uns avec les autres en leur associant des poids. Ils peuvent prendre des données d'entrée, effectuer des opérations simples puis transmettre le résultat à d'autres neurones. La sortie de chaque neurone est appelée sa valeur d'activation [76]. Les ANN sont capables d'apprendre, ce qui se produit en modifiant les valeurs de poids. L'illustration suivante montre un ANN de type multicouches.

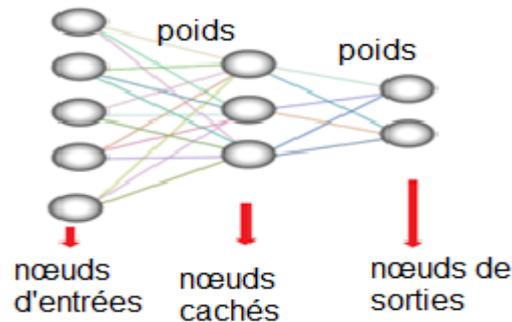


Figure 25: Réseau de neurones artificiel simple

Les nœuds d'entrées prennent des informations, sous la forme de valeurs d'activation, où chaque nœud reçoit une valeur. Cette information est ensuite transmise dans tout le réseau. En fonction des forces de connexion (poids) et des fonctions de transfert, les valeurs d'activation sont propagées d'un nœud à un autre. Chacun des nœuds calcule un état interne qui dépend des valeurs d'activation reçues en entrée et des pondérations associées, puis transforme alors la valeur en appliquant la fonction de transfert. L'activation s'écoule à travers le réseau, à travers des couches cachées, jusqu'à ce qu'elle atteigne les nœuds de sortie. Une distance entre la valeur de sortie prédite et la valeur réelle attendue (l'erreur) est évaluée puis propagée en arrière sous la forme d'un gradient permettant de modifier les poids de chaque nœud en fonction de la quantité d'erreur dont le nœud est responsable.

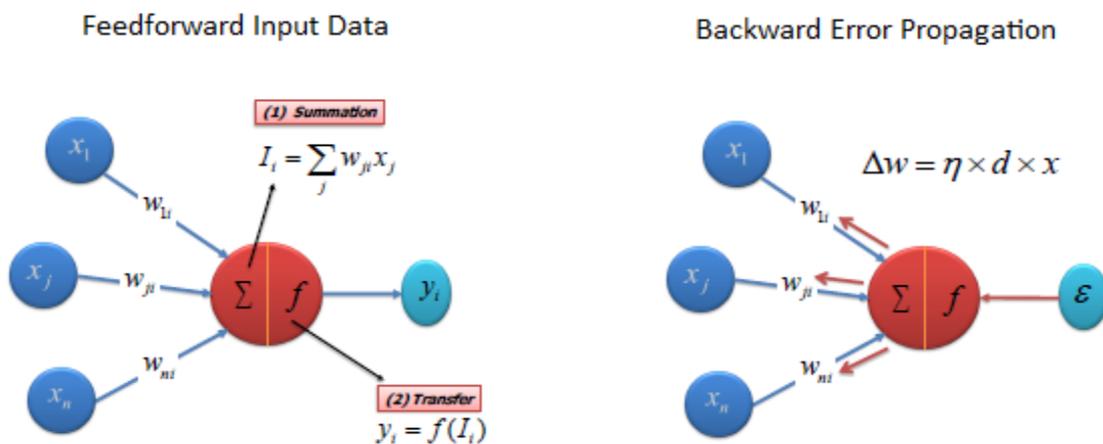


Figure 26: algorithme de calcul de la fonction de transfert

Il existe différents types de réseaux de neurones, mais ils sont généralement classés dans les réseaux 'feed-forward' et 'feed-back'. Un réseau 'feed-forward' est un réseau non récurrent qui contient des entrées, des sorties et des couches cachées; Les signaux ne peuvent circuler que dans une direction. Les données d'entrée sont

transmises sur une couche d'éléments de traitement où elle effectue des calculs. Chaque élément de traitement fait son calcul basé sur une somme pondérée de ses entrées. Les nouvelles valeurs calculées deviennent alors les nouvelles valeurs d'entrée qui alimentent la couche suivante. Ce processus se poursuit jusqu'à ce qu'il ait parcouru toutes les couches et détermine la sortie. Une fonction de transfert de seuil est utilisée pour quantifier la sortie d'un neurone dans la couche de sortie. Les réseaux 'Feed-forward' contiennent les réseaux de base de type Perceptron (linéaire et non linéaire). Les réseaux avancés sont souvent utilisés dans l'exploration de données. Un réseau de type feed-back comporte des arcs qui peuvent transmettre des signaux dans les deux sens en utilisant des boucles. Toutes les connexions possibles entre les neurones sont autorisées. Comme les boucles sont présentes dans ce type de réseau, ils deviennent un système dynamique non linéaire qui évolue continuellement jusqu'à atteindre un état d'équilibre, s'il existe. Les réseaux feed-back sont souvent utilisés dans des mémoires associatives et des problèmes d'optimisation où le réseau recherche le meilleur arrangement de facteurs interconnectés.

La fonction de transfert traduit les signaux d'entrée en signaux de sortie. Cinq types de fonctions de transfert sont couramment utilisés : fonction seuil, sigmoïde, gaussien et linéaire.

La fonction sigmoïde qui est utilisé dans les couches cachées est soit la fonction logistique soit la fonction tangente hyperbolique *tanh*. Les valeurs de la fonction logistique vont de 0 et 1 et -1 à +1 pour la fonction *tanh*.

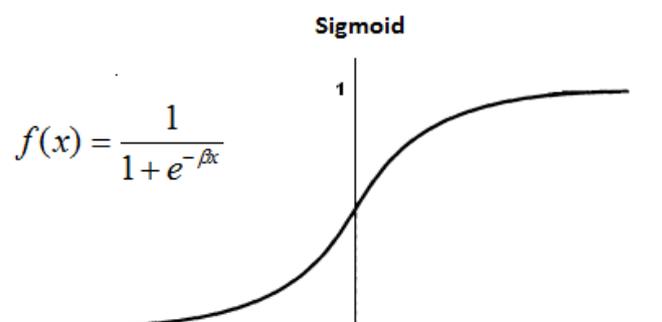


Figure 27: Fonction de transfert sigmoïde.

La fonction linéaire, souvent utilisée dans la couche de sortie pour les problèmes de type régression, transforme les entrées en leur somme pondérée.

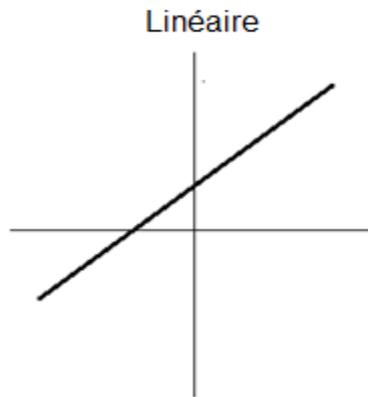


Figure 28: Fonction de transfert linéaire

1.6 Conclusion

L'objectif de la thèse est de définir des caractéristiques du signal EEG pour être utilisées dans la prévision du devenir du nouveau-né prématuré et appliquer des modèles de classification pour évaluer leur pertinence. Dans la première partie de ce chapitre, nous avons catégorisé la prématurité en fonction de l'âge gestationnel qui est un paramètre essentiel pour déterminer des diagnostics d'un prématuré. Nous avons cité les risques et pathologies qui menacent le prématuré. Nous avons présenté un certain nombre de formes typiques du signal EEG et ses relations avec les diagnostics d'un patient. Ensuite nous avons cité dans l'état de l'art les méthodes de prévision du devenir d'un prématuré. Deux méthodes essentielles sont présentées ; la première en fonction de la substance blanche dans l'imagerie à résonance magnétique et la deuxième en fonction des caractéristiques du signal EEG. Plusieurs recherches ont utilisé les aplatissements dans le signal comme marqueur de prévision d'un devenir pathologique mais les travaux qui ont utilisé l'amplitude du signal restent rares. Enfin, nous avons exposé plusieurs modèles de classification et expliqué comment ils peuvent être utilisés.

2 Chapitre 2: Matériels et Méthodes

2.1	Introduction.....	51
2.2	Caractéristiques du signal EEG	51
2.3	Préparation des bases d'apprentissages.....	56
2.3.1	Préparation de la Base BDD_IBI :	57
2.3.2	Préparation de la Base BDD_SEG :	60
2.4	Système d'apprentissage S_APP.	65
2.4.1	Bases d'apprentissage et de test.....	65
2.4.2	Méthodologie de l'apprentissage.	66
2.4.3	Paramètres d'évaluation.....	68
2.5	Conclusion.....	69

2.1 Introduction

Dans ce chapitre, nous allons présenter l'application EEGDiag et expliquer les algorithmes qui détectent les caractéristiques du signal EEG qui sont utiles dans la prévision des pronostics du prématuré. Nous allons expliquer ces caractéristiques et introduire la banque de données utilisée dans le projet ANR BB-EEG de l'hôpital d'Angers, utilisée pour l'apprentissage. Nous allons préparer toutes les informations concernant la base de données BDD_IBI obtenue en détectant ces caractéristiques dans les enregistrements de la banque de données. Nous allons expliquer les motivations pour trouver des nouvelles caractéristiques et détailler la nouvelle base de données BDD_SEG.

2.2 Caractéristiques du signal EEG

Pour extraire du signal EEG des caractéristiques utiles dans la détermination des pronostics, nous avons utilisé une application appelée EEGDiag développée en Java sous la responsabilité du Pr Pierre Chauvet dédiée à l'analyse du signal EEG. Son objectif est d'implémenter des algorithmes de détection des IBI et en construire des indices d'analyse utiles pour le neuro-pédiatre. Elle contient des algorithmes décomposés en un certain nombre d'opérations élémentaires modélisées sous forme de graphes décrivant l'enchaînement de ces opérations. Elle permet d'afficher des EEG sous différents formats (zone 1 dans le graphe) et d'y appliquer des analyseurs (zone 2 dans le graphe) qui segmentent le signal EEG en phases d'activités et phases d'aplatissements selon un seuil prédéfini.

Elle est gérée d'une manière dynamique qui permet de l'enrichir de nouvelles fonctions en se basant sur un mécanisme de plug-in à condition de respecter un Framework bien défini. Ainsi, de nouveaux modules et de nouveaux outils peuvent être ajoutés sous forme de bibliothèque Java (format *.jar) [60].

L'application possède une barre de menus (menus File, Analyze, Tools, Window, Help), une barre d'outils (boutons avec icône Open, Run, Help, boîte à cocher Pre-Filtering) et des zones constituées de un à plusieurs panneaux accessibles par des onglets (numérotés de 1 à 3 dans la Figure 31).

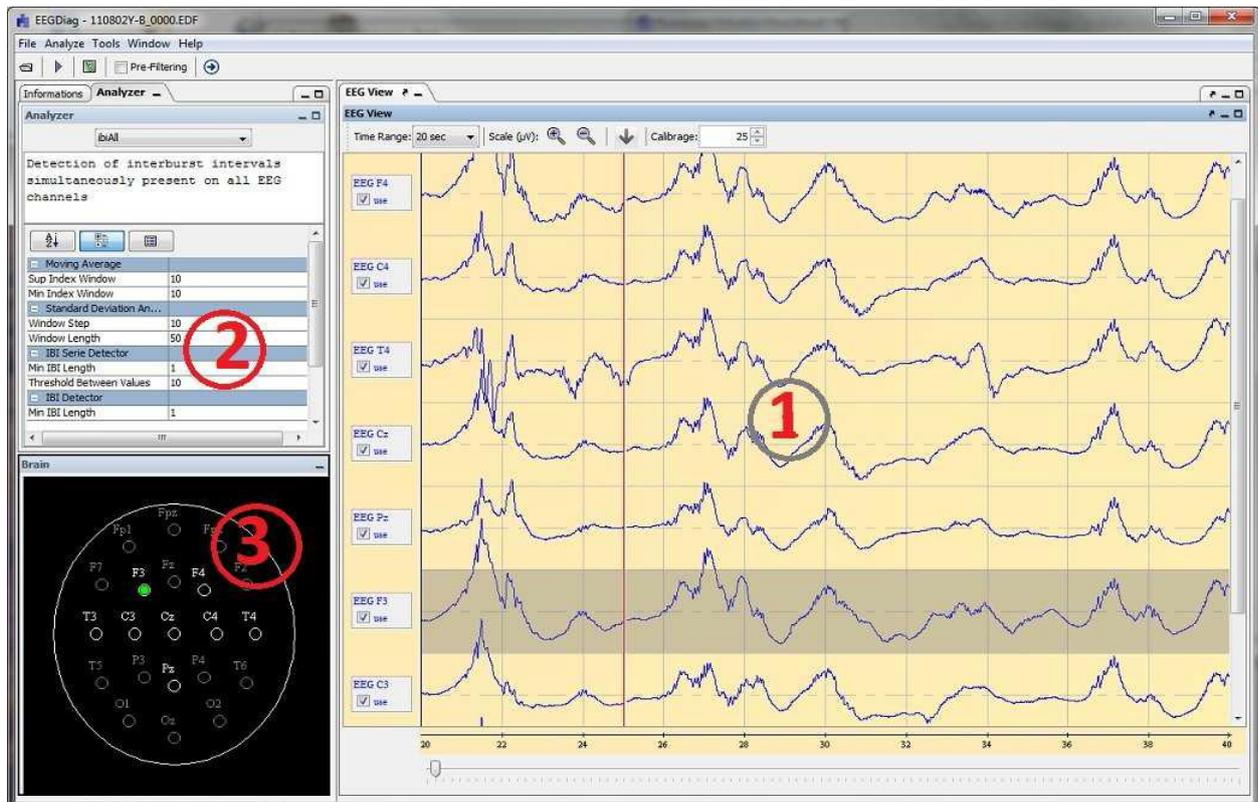


Figure 29: Page d'accueil de EEGDiag

La zone 1 est la zone dite des sorties. Lorsque l'utilisateur ouvre un fichier EEG, les signaux détectés par les différentes électrodes s'affichent dans le panneau « EEG View ». Lorsqu'il lance une analyse, des panneaux supplémentaires avec onglets s'ajoutent pour afficher les résultats intermédiaires et finaux.

La zone 2, ou zone de choix de l'analyseur, permet à l'utilisateur de choisir l'algorithme d'analyse (via le bouton déroulant) parmi tous ceux qui sont disponibles dans le sous-répertoire analyseur. Ce panneau dispose d'une boîte de propriétés, qui permet de modifier les paramètres de l'analyseur choisi. Cette zone contient aussi le panneau à onglet « Informations », qui affiche les informations (lorsqu'elles existent) contenues dans l'entête du fichier EEG ouvert.

La zone 3 représente un crâne avec les positions standards des différentes électrodes EEG. Les électrodes en surbrillance sont celles qui ont été utilisées pour générer le fichier EEG ouvert. Il est possible de cliquer sur une électrode en surbrillance (elle est alors colorée en vert) pour surligner le canal EEG correspondant sur le graphe de la zone 1.

L'analyse du signal EEG est formée d'une suite d'opérations en commençant par l'élimination du bruit et des informations inutiles. Ensuite, il y a une phase d'extraction des informations provenant de différentes sources, puis une phase de leurs agrégations et de leurs transformations sous une forme facile à interpréter. Cette pipeline d'analyse appelé analyseur est implémentée sous forme d'une suite ordonnée de modules parcourus d'une manière séquentielle telle que chaque module envoie ses résultats au module suivant. Toutes les données définies lors de l'exécution de l'analyseur sont sauvegardées dans un fichier texte au format XML.

```

<?xml version="1.0" standalone="true"?>
<!DOCTYPE ANALYZER_MODEL SYSTEM "analyzermodel.DTD">
- <EEG_ANALYZER_MODEL type="sequential" name="IbiAll_Simple">
  <COMMENTS>Detection of interburst intervals simultaneously present on all
  EEG channels using a threshold on amplitude to build an IBI</COMMENTS>
  <HTML>No_Comment_IM.htm</HTML>
  <TAG>IBIDETECTOR</TAG>
  <DATASOURCES>
    <SOURCE name="eeg" class="pc.streameeg.EEGConsultation"/>
  </DATASOURCES>
  <MODULES>
    <MODULE name="smooth01"
      class="bbeeg.modules.smoothing.MovingAverage">
      <SHOWOUTPUT ownview="no"/>
      <PARAMETER name="infIndex" published="yes" value="10"/>
      <PARAMETER name="supIndex" published="yes" value="10"/>
    </MODULE>
    <MODULE name="stddev01"
      class="bbeeg.modules.amplitude.StdDeviation">
      <SHOWOUTPUT ownview="no"/>
      <PARAMETER name="windowStep" published="yes" value="10"/>
      <PARAMETER name="windowLength" published="yes" value="50"/>
    </MODULE>
    <MODULE name="ibidetact01" class="bbeeg.modules.ibi.IBISerieSimple">
      <PARAMETER name="threshold" published="yes" value="20.0f"/>
      <PARAMETER name="minIbiLength" published="yes" value="1.0f"/>
    </MODULE>
    <MODULE name="IbiAll01" class="bbeeg.modules.ibi.IBIAllDetector">
      <SHOWOUTPUT ownview="yes"/>
      <PARAMETER name="minIbiLength" published="yes" value="1.0f"/>
    </MODULE>
  </MODULES>
  <MAINVIEW action="complete" module="IbiAll01"/>
</EEG_ANALYZER_MODEL>

```

Figure 30: Exemple de fichier XML décrivant un analyseur

La méthode utilisée dans l'algorithme de détection des IBI est d'imiter la méthode visuelle admis par les médecins. Selon les médecins la classification d'un IBI est basée essentiellement sur l'aplatissement du signal EEG entre deux bouffées. Par suite, l'algorithme de l'analyseur de EEGDiag qui détecte les IBI consiste à calculer la variation de l'écart-type de chaque point du signal EEG. Un IBI est détecté tant que cette variation est inférieure à une valeur donnée en microvolt et si la durée est supérieure à une valeur donnée en seconde. Les IBI à travers l'EEG sont les intersections des IBI détectés sur chaque canal.

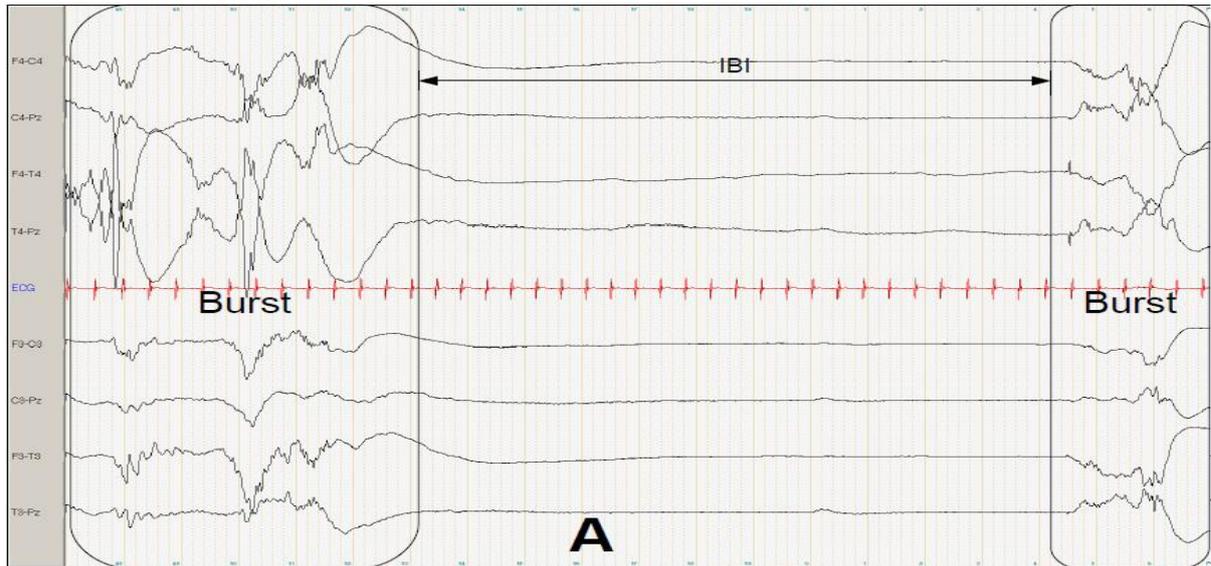


Figure 31: EEG avec deux phases d'activités (Bursts) séparées par un intervalle inter-bouffée (zone A)

Plusieurs modules sont exécutés pour détecter les IBI sur l'ensemble de l'EEG:

- 1- Module Filter: chaque canal est filtré à 50 Hz (fréquence de l'électricité dans l'union européenne).
- 2- Module Smoother: chaque canal est lissé avec une fenêtre mobile par la médiane.
- 3- Module Standard Déviation: chaque canal est parcouru en calculant l'écart-type sur des fenêtres successives pour produire des séries d'écart-types.
- 4- Module IBI Chanel Detector/standard déviation threshold: ce module est formé de 3 phases; dans la première, tant que l'écart-type est inférieur à un certain seuil prédéfini, les points du canal sont agrégés avec l'intervalle précédent. Dans la deuxième regrouper tous les intervalles dont la durée est supérieur à une durée prédéfinie et dans la troisième éliminer les intervalles qui restent.
- 5- Module IBI Chanel Detector/standard déviation variation threshold: ce module est formé de 2 phases; dans la première, tant que la différence entre 2 écart-types successifs est inférieure à un certain seuil prédéfini, un IBI est créé s'il dure plus qu'une valeur prédéfinie, les points du canal sont agrégés avec l'intervalle précédent. Dans la deuxième regrouper tous les intervalles dont la durée est supérieur à une durée prédéfinie.
- 6- Module IBI EEG Detector: calcul des intersections entre chaque série d'IBI, puis éliminer tous les IBI qui durent moins qu'une valeur prédéfinie.

L'analyseur IBI_all_simple de EEGDiag détecte les IBI dans un enregistrement EEG et calcule les valeurs des paramètres suivants pour les intervalles bouffées ainsi que pour les intervalles inter-bouffées (IBI) :

- Nombre de périodes détectés dans la plage de temps du signal EEG analysé.
- Temps cumulé des longueurs détectées en secondes.
- Pourcentage temps cumulé : somme des longueurs divisé par la longueur de la plage de temps analysée.
- Plus longue période en secondes.
- Pourcentage de la plus longue période: longueur de la plus longue période divisé par la longueur de la plage de temps analysée.
- Temps moyen: temps cumulé divisé par le nombre des périodes détectés.

Par exemple, en appliquant IBI_all_simple sur un enregistrement EEG, on a obtenu les résultats suivants:

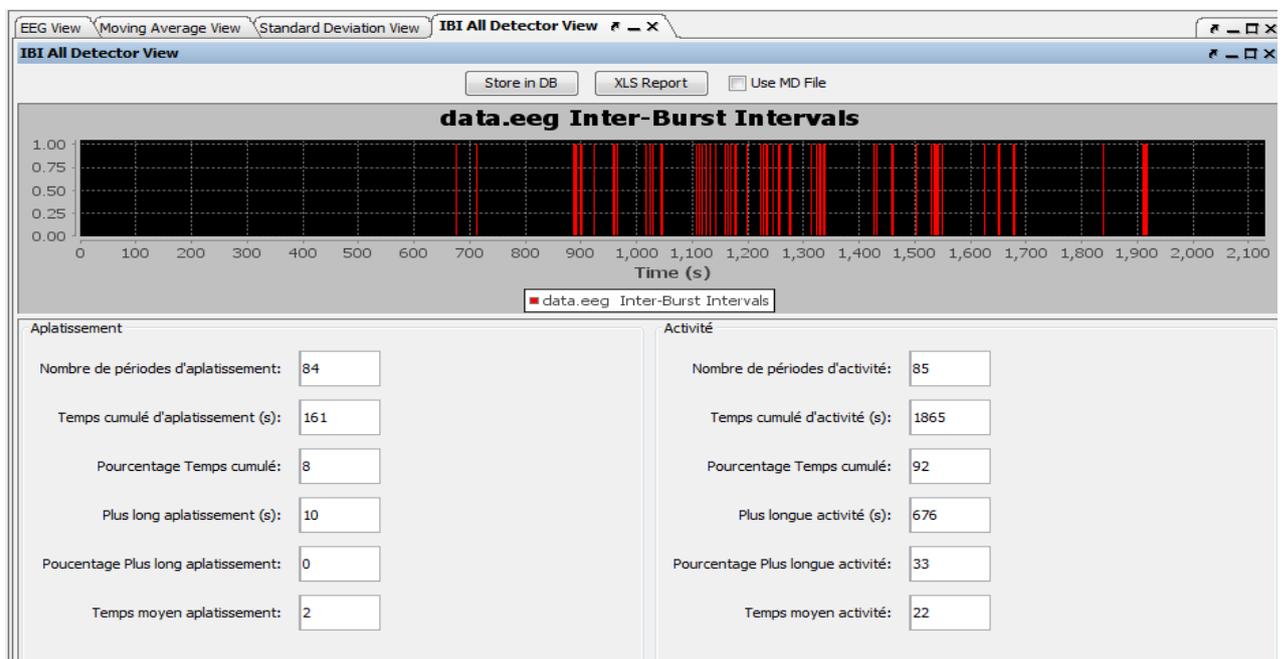


Figure 32: exemple du résultat de l'analyseur IBI_all_simple

Dans cet exemple, on remarque que :

- le nombre de périodes d'aplatissement est de 84 alors que celui de périodes d'activité est de 85. Ces deux nombres sont toujours proches (à +/-1).
- le temps cumulé d'aplatissement est de 161 secondes alors que celui d'activité est de 1865 secondes. Donc une différence importante existe entre les deux temps.

- le pourcentage de Temps cumulé d'aplatissement est de 8 alors que celui d'activité est de 92, qui rendent compte de la différence importante entre IBI et les bouffés, mais indépendamment de la durée totale de l'enregistrement EEG.
- le temps de plus long aplatissement est de 10s alors que celui d'activité est de 676s. Donc la durée du plus long aplatissement est très inférieure à celle de l'activité.
- le pourcentage du plus long aplatissement est $< 1\%$ et qui prend la valeur 0 (dû à l'arrondi), alors que celui d'activité est de 33.
- le temps moyen d'aplatissement est de 2s, alors que celui d'activité est de 22s. Donc la durée moyenne d'activité est supérieure à la durée moyenne d'aplatissement.

Le logiciel est en train d'être enrichi avec des modules pour l'analyse du risque (complexité de Lempel-Ziv, réseaux neuronaux) en utilisant des données sur le devenir de l'enfant. Il existe des travaux qui utilisent l'analyse visuelle des IBI pour corroborer les résultats de l'analyse automatique, mais cela n'est possible que sur quelques EEG. Il est possible de construire des outils d'analyse de la qualité sur des grands corpus d'EEG, à condition que l'analyse automatique de l'EEG repose sur des algorithmes rapides.

2.3 Préparation des bases d'apprentissages.

Les signaux EEG contiennent des caractéristiques déterminantes qui peuvent être utilisées dans l'analyse de l'activité cérébrale. Techniquement, une caractéristique représente une propriété distinctive, une mesure reconnaissable et une composante fonctionnelle obtenue à partir d'une section d'un signal. De nombreuses caractéristiques peuvent être extraites des signaux EEG, comme la fréquence, la transformation de Fourier rapide, l'amplitude du signal, etc. Récemment, une variété de méthodes a été largement décrite pour extraire les caractéristiques déterminantes des signaux EEG. L'extraction de ces caractéristiques à partir d'un ensemble d'enregistrements EEG fournit un ensemble de données d'attributs.

Le projet ANR BB-EEG de l'hôpital Anger a recueilli, entre 2003 et 2008, sous la direction du neuro-pédiatre Professeur Sylvie Nguyen, une banque de données concernant 397 nouveau-nés prématurés, où 273 ont été classés normaux deux ans

après la naissance, 80 douteux et 44 pathologiques, (douteux signifie qu'il n'est pas encore clair si le nouveau-né sera pathologique ou non). Pour chaque bébé, l'enregistrement EEG est fourni avec le diagnostic à la naissance et le diagnostic deux ans plus tard.

Nous allons utiliser cette banque de données pour trouver un système intelligent de classification qui indique des pronostics sur l'état pathologique du nouveau-né prématuré en fonction des données extraites de son EEG à la naissance. La première étape consiste à définir des caractéristiques du signal EEG qui sont liées au pronostic du prématuré.

2.3.1 Préparation de la Base BDD_IBI :

Physiologiquement, un signal EEG est constitué d'une suite d'intervalles bouffés d'amplitude élevée interrompue par des intervalles inter-bouffés (IBI). L'analyseur IBI_all_simple de l'application EEGDiag détecte de chaque intervalle 6 variables qui sont des mesures sur la durée de l'intervalle. Un nombre d'informations supplémentaires (l'âge gestationnel, le jour de l'enregistrement) sont ajoutées. L'âge gestationnel puisque d'après ce qui précède il est fortement corrélé avec la durée des IBI, et le jour de l'enregistrement EEG car chez les nouveau-nés souffrant de l'hypoxie aiguë, l'EEG dépend fortement du jour de l'enregistrement [77]. De plus, Les enregistrements EEG immédiatement après la naissance ont démontré être particulièrement utile pour évaluer le degré de lésions cérébrales et d'élucider leur pathogenèse chez les nourrissons prématurés [78].

Par suite, on définit les 14 variables suivantes :

- les 6 variables sur les intervalles inter-bouffés (IBI) qui sont :
 1. Nombre de période d'aplatissement : N_IBI
 2. Temps cumulé d'aplatissement : TOT_IBI
 3. Pourcentage Temps cumulé d'aplatissement : P_IBI
 4. Le plus long aplatissement : MAX_IBI
 5. Pourcentage du plus long aplatissement : P_MAX_IBI
 6. Temps moyen d'aplatissement : MEAN_IBI
- les 6 variables sur les intervalles bouffés (B) qui sont :
 1. Nombre de période d'activité : N_B

2. Temps cumulé d'activité : TOT_B
 3. Pourcentage Temps cumulé d'activité : P_B
 4. La plus longue activité: MAX_B
 5. Pourcentage de la plus longue activité : P_MAX_B
 6. Temps moyen d'activité : MEAN_B
- Jour de l'enregistrement EEG: OLD
 - l'âge gestationnel en semaine: AG_EEG

En détectant ces variables dans les 397 EEG disponibles par le projet ANR BB-EEG, et en leur ajoutant le diagnostic de l'enfant 2 ans après la naissance nous avons obtenu une base de données relationnelle bien structurée que nous avons appelée BDD_IBI formée de 397 instances, chaque instance contenant 15 attribut, chaque attribut étant l'un des variables.

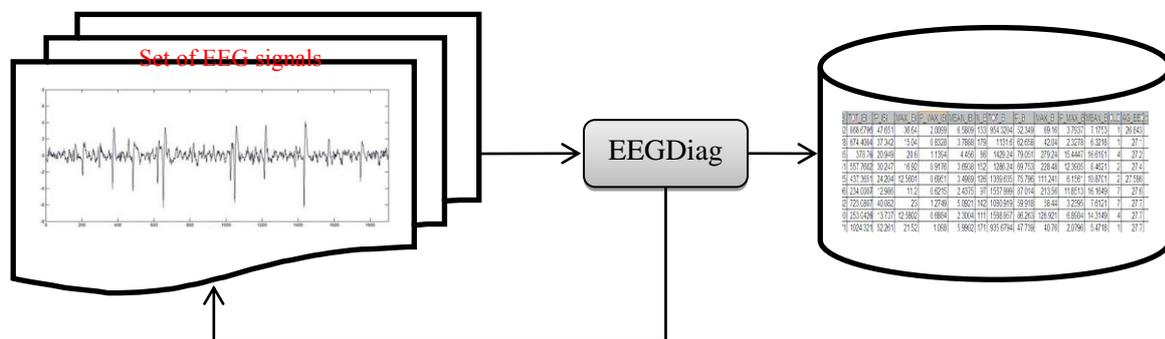


Figure 33: entrée et sortie de EEGDiag

Cette base de données est formée de 14 variables d'entrées. Le diagnostic 2 ans après la naissance (normal, pathologique ou douteux) définit la 15ème variable de la base de données qui est la variable de sortie. D'où le fichier Excel formé des 397 lignes et 15 colonnes suivantes:

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
1	N_IBI	TOT_IBI	P_IBI	MAX_IBI	P_MAX_IBI	MEAN_IBI	N_B	TOT_B	P_B	MAX_B	P_MAX_B	MEAN_B	OLD	AG_EEG	class
2	132	868.6796	47.651	36.64	2.0099	6.5809	133	954.3204	52.349	69.16	3.7937	7.1753	1	26.843	0
3	178	674.4004	37.342	15.04	0.8328	3.7888	179	1131.6	62.658	42.04	2.3278	6.3218	1	27.1	0
4	85	378.76	20.949	20.6	1.1394	4.456	86	1429.24	79.051	279.24	15.4447	16.6191	4	27.2	0
5	151	557.7602	30.247	16.92	0.9176	3.6938	152	1286.24	69.753	228.48	12.3905	8.4621	2	27.4	0
6	125	437.3651	24.204	12.5601	0.6951	3.4989	126	1389.635	75.796	111.241	6.1561	10.8701	2	27.586	0
7	96	234.0007	12.986	11.2	0.6215	2.4375	97	1567.999	87.014	213.56	11.8513	16.1649	7	27.6	0
8	142	723.0807	40.082	23	1.2749	5.0921	142	1080.919	59.918	58.44	3.2395	7.6121	7	27.7	0
9	110	253.0426	13.737	12.3802	0.6884	2.3004	111	1588.957	86.263	126.921	6.8904	14.3149	4	27.7	0
10	171	1024.321	52.261	21.52	1.098	5.9902	171	935.6794	47.739	40.76	2.0796	5.4718	1	27.7	0
11	75	246.4801	13.678	14.2	0.788	3.2864	76	1555.52	86.322	414.44	22.9989	20.4674	1	27.8	0
12	99	330.0801	18.307	23.2	1.2867	3.3341	100	1472.92	81.693	180.68	10.0211	14.7292	1	27.8	0
13	135	414.2044	19.781	22.0001	1.0506	3.0682	136	1679.796	80.22	255.002	12.1778	12.3514	2	27.9	0
14	121	606.92	34.135	19.12	1.0754	5.0159	122	1171.08	65.865	190.68	10.7244	9.5599	6	28	0
15	114	328.7236	18.242	12.1201	0.6726	2.8835	114	1473.276	81.758	279.163	15.4918	12.9235	6	28	0

Figure 34 : exemple du fichier Excel obtenu par l'application de EEGdiag sur les EEG de ANR BB-EEG

Les 14 premières colonnes sont les 14 variables d'entrée déjà définis, la quinzième colonne est la classe qui est la variable de sortie et qui prend l'une des trois valeurs 0, 1 ou 2. Le chiffre 0 correspond à un devenir normal, 1 un devenir douteux et 2 un devenir pathologique de l'enfant prématuré. Ce fichier va être la base d'apprentissage sur laquelle on va appliquer des modèles de classification. Les premières 14 colonnes forment la matrice d'entrée et la quinzième colonne le vecteur de sortie. Ces modèles utilisent des fonctions de transfert dont les valeurs doivent être normalisées entre -3 et 3 pour les fonctions sigmoïdes. Donc on doit normaliser les valeurs de la matrice d'entrée en utilisant la fonction suivante :

$$X_i = \frac{X_i - X_{min}}{X_{max} - X_{min}}$$

Où «i» représente le numéro de la ligne de la matrice d'entrée, X_i est la valeur dans chaque colonne, X_{min} et X_{max} sont la plus petite et la plus grande valeur respectivement du vecteur X .

D'autre part, Pour obtenir trois classes dans la matrice de sortie, On a associé pour la quinzième colonne du fichier Excel les valeurs suivantes : [0 0 1] qui correspond à 0, [0 1 0] qui correspond à 1 et [1 0 0] qui correspond à 2.

Les 397 enregistrements sont partagés en 273 enregistrements de classe « normal », 80 enregistrements de classe « douteux » et 44 enregistrements de classe « pathologique ». Par suite le nombre des enregistrements normaux est très supérieur au nombre des enregistrements pathologiques et douteux, donc l'ensemble de données est déséquilibré. Les ensembles de données sont déséquilibrés quand au moins une classe est représentée par un petit nombre d'exemples (appelé la classe minoritaire), tandis que d'autres classes constituent la majorité. Dans ce scénario, les classifieurs peuvent avoir une bonne précision sur les classes majoritaires mais une très mauvaise précision sur les classes minoritaires. Un certain nombre de solutions au problème de classes déséquilibrées ont été proposées tant au niveau des données et qu'au niveau des algorithmes. Une méthode facile au niveau des données pour rééquilibrer les classes est de ré-échantillonner l'ensemble de données d'origine, soit par sur-échantillonnage de la classe minoritaire ou par le sous-échantillonnage de la classe majoritaire, jusqu'à ce que les classes soient à peu près également représentées [79]. Les deux stratégies

peuvent être appliquées dans tout système d'apprentissage, car ils agissent comme une phase de prétraitement, permettant au système de recevoir les instances de l'apprentissage comme si elles appartenait à un ensemble de données bien équilibré. Ainsi, toute déviation du système vers la classe majoritaire devrait être supprimée. Pour éviter la perte des cas qui peuvent être utiles dans l'apprentissage (du fait d'un nombre peu élevé d'exemples), nous avons choisi de sur-échantillonner les classes minoritaires. Pour cela, nous avons ré-échantillonné les enregistrements de la classe douteux et la classe pathologique pour obtenir 258 enregistrements de classe douteux et 209 enregistrements de classe pathologique.

Pour évaluer le système intelligent que nous allons construire par apprentissage à partir de l'ensemble de données obtenus, il faut subdiviser les instances de la base de données déjà préparée en deux parties ; la première pour l'apprentissage et la deuxième pour le test pour évaluer la performance du système trouvé en comparant son résultat avec des résultats réels. Dans la littérature, normalement on réserve jusqu'à 40% de la base d'apprentissage pour le test, dans notre étude nous avons choisi 80% des instances pour l'apprentissage et le 20% qui reste pour valider la performance du système trouvé en comparant son résultat à celui donné par les médecins. Par suite les 273 enregistrements de la classe normale sont partagés en 219 pour l'apprentissage et 54 pour le test. Les 258 enregistrements de la classe douteuse sont partagés en 206 pour l'apprentissage et 52 pour le test. Les 209 enregistrements de la classe pathologique sont partagés en 168 pour l'apprentissage et 41 pour le test. Cette base de données que nous appelons BDD-IBI est une base de données bien structurée et équilibrée, prête à être utilisée dans l'apprentissage par machine pour réaliser un système de classification intelligent qui détecte le pronostic du prématuré depuis sa naissance.

2.3.2 Préparation de la Base BDD_SEG :

Bien que les IBI soient largement utilisés pour prédire les résultats neurologiques du prématuré, l'utilisation d'une information d'amplitude faible ou forte dans les intervalles bouffés du signal EEG est encore limitée.

Les modèles dans BDD-IBI étaient basés sur une segmentation du signal EEG en intervalles bouffés et en intervalles inter-bouffés avec un seuil de $20\mu\text{v}$. Cela signifie que tous les signaux ayant une amplitude supérieure à $20\mu\text{v}$ ont été regroupés dans

les mêmes intervalles et ont des effets similaires dans la classification. Cela peut causer une perturbation dans l'apprentissage qui va conduire à une mauvaise classification, car, selon les annotations des médecins, une faible amplitude dans le signal EEG est un modèle qui indique une réduction de l'activité cérébrale similaire à celui des IBI alors qu'une amplitude élevée est un modèle qui indique une augmentation de l'activité dans le cerveau.

D'autre part, une étude bibliographique sur l'amplitude d'un signal EEG a montré que les faibles amplitudes dans les intervalles bouffés du signal EEG sont fortement corrélées à une anomalie dans le pronostic de l'état pathologique du prématuré [80]. Dans BDD-IBI, Les intervalles de faible amplitude dans le signal EEG vont être traités de la même manière que les intervalles d'amplitude moyenne et haute dans le signal. Ensuite, un certain nombre d'enregistrements ayant des intervalles de faible amplitude vont être classés normaux alors qu'ils étaient classés malades ou douteux par les médecins.

Pour éviter cette perturbation dans notre travail, nous avons segmenté l'amplitude des bouffés dans le signal EEG en trois nouveaux intervalles: faible, moyen et fort. Dans la littérature, de nombreuses valeurs de seuils entre ces intervalles sont proposées. Dans notre travail, nous avons essayé au début les seuils suivants [57]:

- L'IBI est l'intervalle dont l'amplitude est inférieure à 20 μv
- la faible amplitude est comprise entre 20 μv et 50 μv ,
- l'amplitude moyenne entre 50 μv et 100 μv
- l'amplitude forte supérieure à 100 μv .

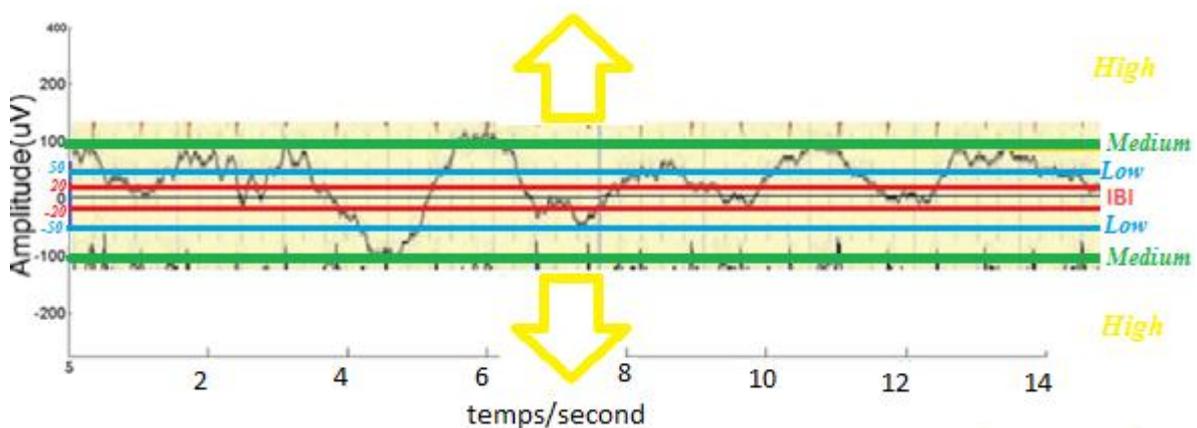


Figure 35: segmentation du signal EEG en IBI, amplitude faible, moyenne et forte

Nous avons créé un nouvel analyseur appelé **SegEEG** qui segmente un signal EEG en 3 segments: faible, moyen et fort puis extrait les caractéristiques appropriées de chaque segment. La figure suivante montre l'architecture de l'analyseur **SegEEG**. Cet analyseur est composé de plusieurs modules qui sont *StDeviation*, *Segmentation*, *Intersection* et *ParameterDetector*.

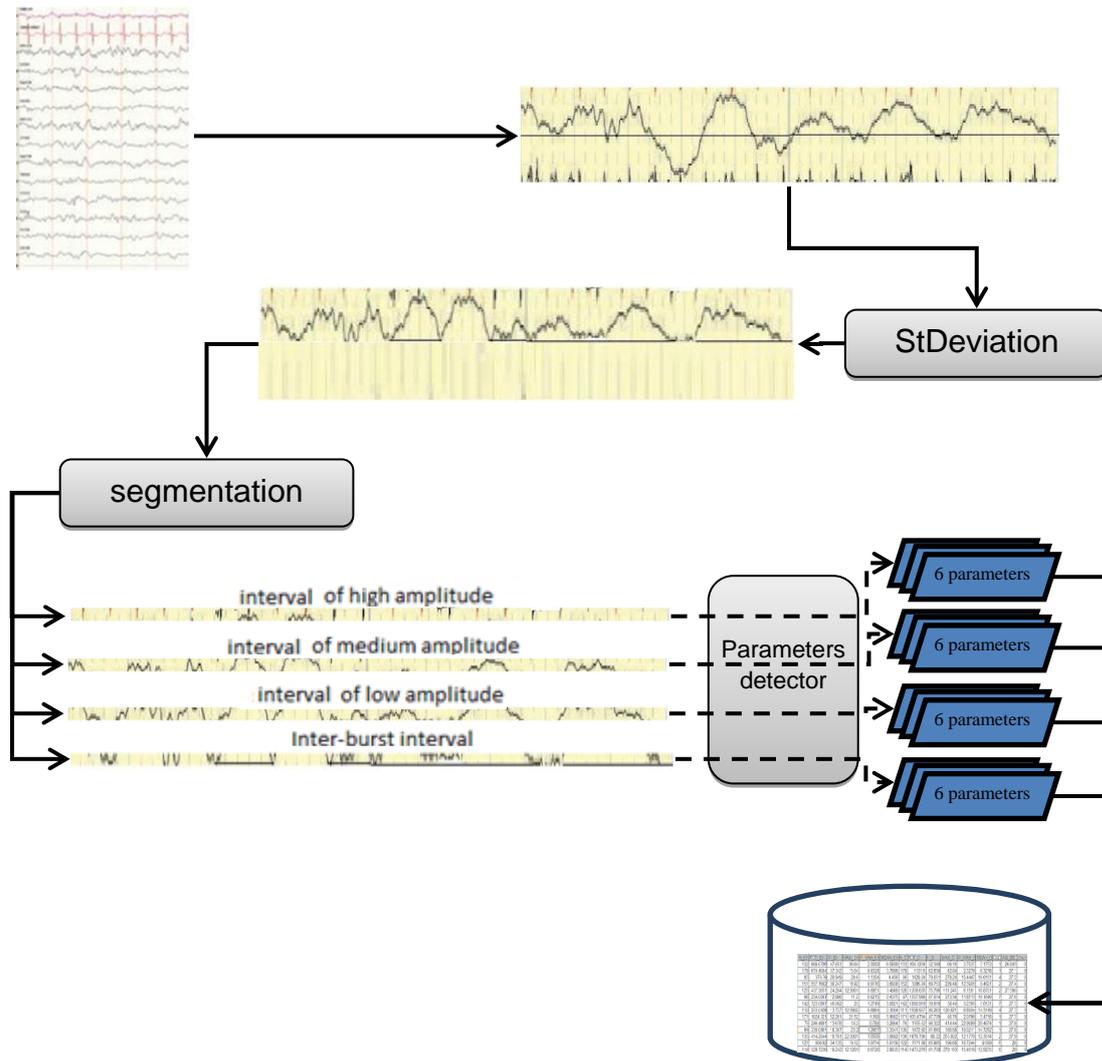


Figure 36: illustration de l'algorithme de SegEEG

Un enregistrement EEG contient un canal de signal EEG pour chaque électrode. Ces canaux sont détectés par EEGDiag. Le premier module de notre analyseur SegEEG est StDeviation qui reçoit ces signaux et calcule la valeur absolue de l'écart type sur des fenêtres successives, pour produire des séries d'écarts types. Le deuxième module est la segmentation qui reçoit la série des écarts types et les segmente en IBI, amplitude faible, moyenne et forte, en fonction des seuils déjà définis. Ainsi, pour

chaque série d'écart types, si l'écart type appartient à l'un des 4 segments, l'intervalle de temps correspondant est agrégé avec l'intervalle d'écart type du même segment. Le module intersection calcule les intersections entre chaque série de tous les canaux, puis élimine tous les intervalles ayant une durée inférieure à une seconde. Enfin, le module parametersdetector calcule les 6 variables des intervalles de chaque segment.

Les données trouvées en exécutant cet analyseur sont sauvegardées dans le fichier texte XML suivant :

```
<?xml version="1.0" standalone="yes" ?>
<!DOCTYPE ANALYZER_MODEL (View Source for full doctype...)>
- <EEG_ANALYZER_MODEL name="ibiAll_Complex" category="IBI detection" type="sequential">
  <COMMENTS>Detection of interburst intervals and burst(faible,Moyenne,Forte) simultaneously present on all EEG channels</COMMENTS>
  <HTML>No_Comment_IM.htm</HTML>
  <TAG>IBIDETECTOR</TAG>
- <DATASOURCES>
  <SOURCE name="eeg" class="pc.streameeg.EEGConsultation" />
</DATASOURCES>
- <MODULES>
- <MODULE name="smooth01" class="bbeeg.modules.smoothing.MovingAverage">
  <SHOWOUTPUT ownview="yes" />
  <PARAMETER name="infIndex" value="10" published="yes" />
  <PARAMETER name="supIndex" value="10" published="yes" />
</MODULE>
- <MODULE name="stddev01" class="bbeeg.modules.amplitude.StdDeviation">
  <SHOWOUTPUT ownview="yes" />
  <PARAMETER name="windowStep" value="10" published="yes" />
  <PARAMETER name="windowLength" value="50" published="yes" />
</MODULE>
- <MODULE name="ibidet02" class="bbeeg.modules.ibi.IBISerieComplex">
  <PARAMETER name="thresholdParam" value="20.0f" published="yes" />
  <PARAMETER name="thresholdParamFaible" value="50.0f" published="yes" />
  <PARAMETER name="thresholdParamMoyenne" value="100.0f" published="yes" />
  <PARAMETER name="minIbiLength" value="1.0f" published="yes" />
</MODULE>
- <MODULE name="ibiAll02" class="bbeeg.modules.ibi.IBIAllDetectorComplex">
  <SHOWOUTPUT ownview="yes" />
  <PARAMETER name="minIbiLength" value="1.0f" published="yes" />
</MODULE>
</MODULES>
<MAINVIEW module="ibiAll02" action="complete" />
</EEG_ANALYZER_MODEL>
```

Figure 37: Exemple de fichier XML décrivant SegEEG

Le résultat final de l'application de l'analyseur SegEEG sur les 397 enregistrements EEG est une nouvelle base de données bien structurée que nous appelons BDD_SEG qui contient 27 variables pour 397 patients.

Figure 38: exemple de fichier Excel obtenu par l'application de SegEEG sur les EEG de ANR BB-EEG.

Ensuite, BDD_SEG est formé de 27 attributs et 397 instances illustrés à la figure précédente. Les premiers 24 attributs sont les variables détectés par SegEEG et les

3 autres variables sont le jour de l'enregistrement, l'âge gestationnel de la prématurité et une classe normale, pathologique ou douteux. Le chiffre «0» correspond à « normal », «1» correspond à « douteux » et «2» correspond à « pathologique ».

Les 27 attributs de **BDD_SEG** sont les suivants :

- les 6 variables sur les intervalles d'aplatissement (IBI) :
 - 1 Nombre de période d'aplatissement : *N_B_IBI*
 - 2 Temps cumulé d'aplatissement : *TOT_IBI*
 - 3 Pourcentage Temps cumulé d'aplatissement : *P_IBI*
 - 4 Le plus long aplatissement : *MAX_IBI*
 - 5 Pourcentage du plus long aplatissement : *P_MAX_IBI*
 - 6 Temps moyen d'aplatissement : *MEAN_IBI*

- les 6 variables sur les intervalles d'activité faible :
 - 7 Nombre de période d'activité faible : *N_B_faible*
 - 8 Temps cumulé d'activité faible : *TOT_B_faible*
 - 9 Pourcentage Temps cumulé d'activité faible: *P_B_faible*
 - 10 La plus longue activité faible: *MAX_B_faible*
 - 11 Pourcentage de la plus longue activité faible : *P_MAX_faible*
 - 12 Temps moyen d'activité faible: *MEAN_B_faible*

- les 6 variables sur les intervalles d'activité moyenne (*B_moy*) :
 - 13 Nombre de période d'activité moyenne : *N_B_moy*
 - 14 Temps cumulé d'activité moyenne: *TOT_B_moy*
 - 15 Pourcentage Temps cumulé d'activité moyenne: *P_B_moy*
 - 16 La plus longue activité moyenne: *MAX_B_moy*
 - 17 Pourcentage de la plus longue activité moyenne : *P_MAX_B_moy*
 - 18 Temps moyen d'activité moyenne : *MEAN_B_moy*

- les 6 variables sur les intervalles d'activité forte:
 - 19 Nombre de période d'activité forte : *N_B_fort*
 - 20 Temps cumulé d'activité forte: *TOT_B_fort*
 - 21 Pourcentage Temps cumulé d'activité forte: *P_B_fort*
 - 22 La plus longue activité forte: *MAX_B_fort*

23 Pourcentage de la plus longue activité forte : *P_MAX_B_fort*

24 Temps moyen d'activité forte : *MEAN_B_fort*

25 Jour de l'enregistrement EEG: *OLD*

26 l'âge conceptuel en semaine: *AG_EEG*

27 le diagnostic: *Class*

2.4 Système d'apprentissage S_APP.

Le système S_APP est une application développée sous Matlab qui a comme source une base de données ayant des attributs d'entrés et une classe de sortie. Il utilise 80% des effectifs de la base de données pour l'apprentissage afin de trouver une fonction de prévision de la classe, et les 20% restants pour l'évaluer en comparant ses résultats avec leur classe réelle.

2.4.1 Bases d'apprentissage et de test.

Pour que la fonction de prédiction soit performante le système S_APP choisit les instances d'apprentissage et de test comme l'indique l'algorithme suivant illustré dans figure 39 :

- 1- On décompose les instances de la base de données en 5 sous-ensembles, on en choisit 1 pour le test et les 4 qui restent pour l'apprentissage.
- 2- On sélectionne un des modèles (régression linéaire multiple, analyse discriminante linéaire, machine à vecteur de support, réseau de neurones artificiel et arbre de décision).
- 3- On applique l'apprentissage pour produire un résultat pour le modèle sélectionné.
- 4- Ce processus est répété 5 fois en choisissant chaque fois un autre sous-ensemble pour le test et le restes pour l'apprentissage.
- 5- On calcule la moyenne des 5 résultats ainsi obtenus pour le modèle sélectionné.
- 6- Ce processus est répété pour les autres modèles.

L'application de cet algorithme minimise les effets de la répartition des instances en 2 ensembles (test et apprentissage), étant donné que cette répartition est arbitraire et produit des résultats différents à chaque fois.

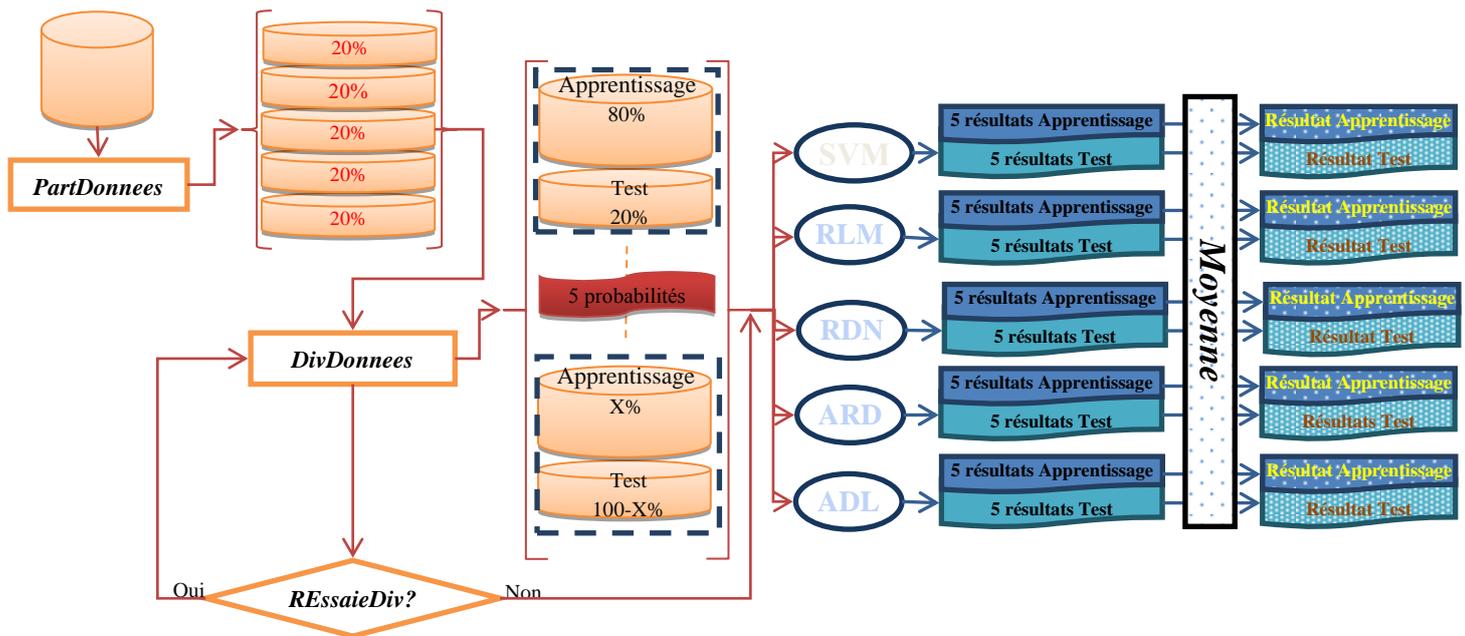


Figure 39: Architecture générale du système d'apprentissage « S_APP ». Les méthodes d'apprentissage utilisées sont : SVM (support vector machine), MLR (régression Linéaire multiple), ANN (réseau de neurones artificiels), DT (arbre de décision) et LDA (analyse discriminante linéaire).

2.4.2 Méthodologie de l'apprentissage.

Nous décrivons ci-dessous les méthodes d'apprentissage utilisées avec les cinq modèles présentés dans le paragraphe 1.5, testées sur les données précédemment décrites.

1- **MLR**: L'analyse de régression linéaire multiple est effectuée pour prévoir les valeurs d'une variable dépendante Y , en fonction d'un ensemble de p variables explicatives (X_1, X_2, \dots, X_p) . Une régression linéaire simple est effectuée pour estimer la relation entre une variable dépendante Y , et une seule variable explicative X , en fonction d'un ensemble de données qui comprend des observations pour ces deux variables pour une population donnée [83]. Cette méthode ne nécessite aucun paramétrage et les seules entrées sont l'ensemble d'apprentissage avec les classes associées.

2- **LDA**: L'analyse discriminante linéaire (LDA) est une technique couramment utilisée pour la classification des données et la réduction de la dimension. L'analyse discriminante linéaire gère facilement le cas où les fréquences internes sont inégales et leurs performances ont été examinées sur des données de test générées au hasard [84]. La méthode LDA considère que les variables explicatives suivent une loi

normale multidimensionnelle et que toutes les matrices de variances conditionnelles sont égales.

3- **SVM** : Une machine à vecteurs supports (SVM) est un algorithme d'apprentissage supervisé qui peut être utilisé à la fois pour la classification ou la régression. Les SVMs sont conçus initialement pour les problèmes de classification binaire, et ensuite généralisés pour traiter le cas de classification multiclassés. Nous avons choisi le noyau radial qui est le plus couramment utilisé vu les performances qu'il donne sur les problèmes les plus complexes. Le paramètre Σ^2 de ce noyau ainsi que le paramètre de coût d'erreur C pour l'algorithme SVM sont choisis par des méthodes de validation.

4- **ANN** : Les réseaux de neurones artificiels (ANN) se composent de variables d'entrées appelées synapses qui sont multipliées par des poids, puis calculées par une fonction mathématique. L'algorithme utilisé dans les ANN ajuste les poids d'un neurone artificiel pour obtenir la sortie souhaitée pour des entrées spécifiques. Ce processus d'ajustement des poids est appelé apprentissage [85].

Le ANN construit dans S_APP comprend une couche d'entrées qui contient un nombre de variables d'entrées égales au nombre d'attributs dans la base de données et une couche de 3 variables de sortie. Dans la littérature, le nombre de neurones utilisé dans la couche cachée est majoritairement pris égal au double du nombre des variables d'entrées, ou bien égal à un nombre compris entre le nombre des variables d'entrées et le nombre des variables de sorties. D'après plusieurs tests que nous avons essayés, nous avons trouvé qu'un nombre double de neurones dans la couche cachée que celles de la couche d'entrées, a donné une meilleure performance. Le ANN construit utilise la procédure *Trainlm* pour l'apprentissage qui a une fonction de transfert sigmoïde. Cette fonction est adaptée pour un grand nombre d'entrées non linéaires. Elle choisit aléatoirement les poids synaptiques (w) et les biais (b), puis modifie leurs valeurs selon l'algorithme de Levenberg-Marquardt. Cet algorithme s'arrête après 1000 itérations ou lorsque la valeur de moindre carré est inférieure à un seuil à fixer. Dans notre cas, nous avons choisi la valeur 0,05.

5- **DT** : L'arbre de décision a pour objectif de trouver une relation forte entre les valeurs d'entrée et les valeurs de sorties dans un groupe d'ensemble de données. Lorsqu'un ensemble de valeurs d'entrée a une relation forte avec une valeur sortie, toutes ces valeurs forment une branche dans l'arbre de décision. La mise en œuvre de cette méthode ne nécessite aucun paramétrage et se base principalement sur un

critère qui permet de choisir le nœud à une étape donnée, qui constitue un test sur la meilleure variable explicative qui doit servir pour séparer les sous arbre gauche du sous arbre droite.

2.4.3 Paramètres d'évaluation

S_APP présente les paramètres d'évaluations de l'apprentissage de chaque modèle sous forme de deux tableaux : le premier pour l'apprentissage et le deuxième pour le test. Chaque tableau est formé de cinq colonnes et 6 lignes. Les lignes présentent les valeurs prédites et les colonnes présentent les valeurs réelles. Par suite, chaque tableau est représenté de la manière suivante :

Réel \ Prédit	Pathologique (P)	Douteux (D)	Normal (N)	Précision
Pathologique (P)	a	b	c	$\frac{a}{a+b+c}$
Douteux (D)	d	e	f	$\frac{e}{d+e+f}$
Normal (N)	g	h	i	$\frac{i}{g+h+i}$
Rappel	$\frac{a}{a+d+g}$	$\frac{e}{b+e+h}$	$\frac{i}{c+f+i}$	Exactitude
F_Mesure				

Tableau 2: représentation des résultats

a= P prédit sachant que P réel. b= P prédit sachant que D réel. c= P prédit sachant que N réel.
d= D prédit sachant que P réel. e= D prédit sachant que D réel. f= D prédit sachant que N réel.
g= N prédit sachant que P réel. h= N prédit sachant que D réel. i= N prédit sachant que N réel.

Précision: parmi toutes les instances prédites d'une classe, combien d'instances ont été correctement prédites?

Rappel: parmi toutes les instances réelles d'une classe, combien d'entre elles ont été correctement prédites?

$$F_Mesure = \frac{2 \times Précision \times Rappel}{Précision + Rappel}$$

$$Exactitude = \frac{a + e + i}{a + b + c + \dots + i}$$

On va évaluer la performance des résultats en fonction des valeurs de F_Mesure. Selon l'avis d'un expert la catégorisation des résultats peut être classée comme suit [88]:

- Une valeur F_Mesure inférieure à 70 est considérée comme Mauvaise ;
- Une valeur F_Mesure comprise entre 70 et 85 est considérée comme Moyenne ;
- Une valeur F_Mesure supérieure à 85 est considérée comme Forte.

2.5 Conclusion

Dans ce chapitre nous avons préparé deux bases de données pour être utilisé dans les méthodes d'apprentissage, BDD_IBI et BDD_SEG. Les attributs d'entrées de BDD_IBI sont des caractéristiques dans le signal EEG basés sur la segmentation du signal en deux phases : bouffées et inter-bouffées. Les attributs d'entrées de BDD_SEG sont des caractéristiques dans le signal EEG basés sur la segmentation du signal en quatre phases : inter-bouffées, bouffées faibles, bouffées moyennes et bouffées fortes. Nous avons développé des analyseurs pour les extraire d'un enregistrement EEG. En appliquant ces analyseurs sur un ensemble de données formé de 397 nouveau-nés prématurés offerts par l'hôpital d'Angers, nous avons obtenu les deux bases de données formées de 397 instances. L'attribut de sortie pour les deux bases est la classe : normale, pathologique ou douteuse. Nous avons équilibrés le nombre d'instances des trois classes pour éviter le biais dans l'apprentissage vers la classe majoritaire en ré-échantillonnant les classes minoritaires. Nous avons divisé chaque base en deux sous ensemble : la première formée de 80% de la base pour l'apprentissage et la deuxième formée de 20% pour le test. Ainsi, les deux bases de données sont formées de :

- 209 instances de classe pathologique, 168 pour l'apprentissage et 41 pour le test,
- 258 instances de classe douteuse, 206 pour l'apprentissage et 52 pour le test,
- 273 instances de classe normale, 219 pour l'apprentissage et 54 pour le test.

3 Chapitre 3: Résultats et discussion

3.1	Introduction.....	71
3.2	Application de S_APP sur BDD-IBI.	72
3.2.1	Régression linéaire multiple.....	72
3.2.2	Analyse discriminante linéaire	73
3.2.3	Machine à Vecteurs de Supports.....	73
3.2.4	Réseau de neurones artificiel	74
3.2.5	Arbre de décision.....	75
3.2.6	Discussion des résultats.....	76
3.3	Application de S_APP sur BDD_SEG.....	78
3.3.1	Régression linéaire multiple.....	79
3.3.2	Analyse discriminante linéaire	79
3.3.3	Machine à Vecteurs de Supports.....	80
3.3.4	Réseau de neurones artificiel	81
3.3.5	Arbre de décision.....	82
3.3.6	Discussion des résultats.....	83
3.4	Choix des seuils dans la segmentation.	84
3.5	Proposition des caractéristiques utiles du signal EEG	86
3.6	Conclusion.....	89

3.1 Introduction

L'apprentissage automatique est le sous-domaine de l'intelligence artificielle qui donne aux ordinateurs la possibilité d'apprendre sans être programmé explicitement [81]. Son objectif est de construire des algorithmes qui peuvent apprendre et faire des prévisions ou des décisions basées sur les données [82]. L'apprentissage automatique étant une tâche de classification, est capable d'offrir des techniques pour extraire des données ayant des modèles communs ensuite prendre des décisions précieuses, en fonction des comportements appris.

L'objectif de l'apprentissage automatique est de construire un système intelligent de classification en profitant d'un ensemble de données existant pour déterminer une fonction de prévision concernant des nouvelles données. L'ensemble de données doit avoir des attributs, et des classes qui peuvent être déduites en fonction de ces attributs. Dans le domaine médical, l'apprentissage sur un ensemble de patients existant ayant des diagnostics, est utilisé pour prévoir les pronostics des nouveaux patients (Fig.40).

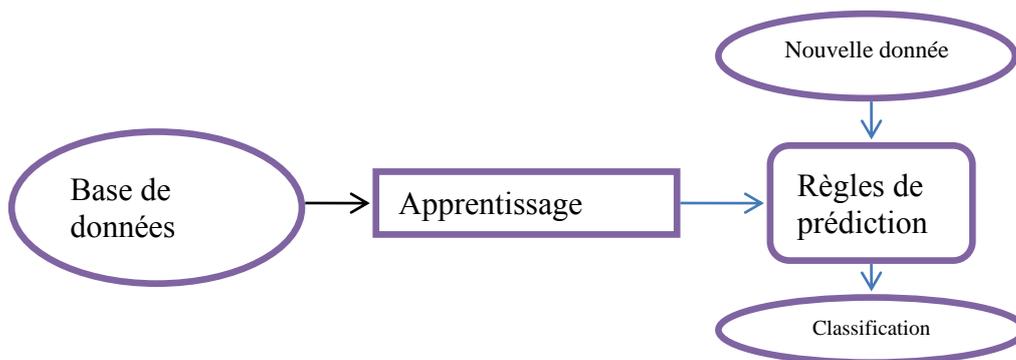


Figure 40: schéma d'apprentissage

Normalement, l'ensemble des données dédié à l'apprentissage est partagé en deux sous-ensembles : la plus grande partie pour l'apprentissage et le reste pour évaluer la fonction de prévision en comparant ses résultats avec les données réelles. Dans notre étude, nous avons utilisé 80% de la base de données pour l'apprentissage et le 20% restant pour le test, ce qui fait 592 enregistrements pour l'apprentissage et 148 enregistrements pour le test.

3.2 Application de S_APP sur BDD-IBI.

Pour trouver une fonction automatique qui déduit la classe de l'état pathologique du prématuré (normale, douteux ou pathologique) à partir des variables détectés dans son EEG, nous avons exécuté S_APP sur BDD_IBI. Les résultats obtenus sont les suivants.

3.2.1 Régression linéaire multiple

Les résultats de la régression linéaire multiple sont les suivants:

Dans l'ensemble d'apprentissage, ce modèle a seulement correctement classé 58 enregistrements parmi 168 enregistrements pathologique (34,5%), 166 enregistrements parmi 206 enregistrements douteux (80,6%) et 29 enregistrements parmi 219 enregistrements normaux (13,2%).

Dans l'ensemble test, parmi 41 enregistrements classés pathologiques par les médecins, nous avons obtenu 14 pathologiques, 26 douteux et 1 normaux; Parmi les 52 enregistrements classés douteux par les médecins, nous avons obtenu 8 pathologiques, 41 douteux et 3 normaux; Et parmi 54 enregistrements classés normaux par les médecins, nous avons obtenu 7 pathologiques, 39 douteux et 8 normaux. Ainsi, le rappel a été de 34,1% (14/41) dans la classe pathologique, 78,4% (41/52) dans la classe douteuse et 12,9% (7/54) dans la classe normale. La précision a été de 46,7% dans la classe pathologique, 38,1% dans la classe douteuse et 63,6% dans la classe normale. L'exactitude a été de 42,5% comme le montre tableau 3. Ce modèle a donné une performance mauvaise pour toutes les classes.

Apprentissage					Test				
	P	D	N			P	D	N	
P	58	25	13	60,4%	P	14	8	8	46,7%
D	110	166	177	36,6%	D	26	41	39	38,1%
N	0	15	29	65,9%	N	1	3	7	63,6%
	34,5%	80,6%	13,2%	42,7%		34,1%	78,4%	12,9%	42,5%
F	43,9	50,34	22,0		F	39,4	51,3	21,4	

Tableau 3: Résultat obtenu appliquant la régression linéaire multiple sur BDD_IBI.

3.2.2 Analyse discriminante linéaire

Les résultats de la LDA sont les suivants:

Dans l'ensemble d'apprentissage, ce modèle a seulement correctement classé 90 enregistrements sur 168 enregistrements pathologiques (53,6%), 72 enregistrements parmi 206 enregistrements douteux (35,0%) et 116 enregistrements parmi 219 enregistrements normaux (53,0%).

Dans l'ensemble de tests, parmi 41 enregistrements classés pathologiques par les médecins, nous avons obtenu 19 pathologiques, 7 douteux et 15 normaux; Parmi les 52 enregistrements classés douteux par les médecins, nous avons obtenu 20 pathologiques, 9 douteux et 23 normaux; Et parmi 55 enregistrements classés normaux par les médecins, nous avons obtenu 15 pathologiques, 11 douteux et 28 normaux. Ainsi, le rappel était 46,3% dans la classe pathologique, 17,3% dans la classe douteuse et 51,8% dans la classe normale. La précision a été de 35,2% dans la classe pathologique, 33,3% dans la classe douteuse et 42,8% dans la classe normale. L'exactitude a été 38,1% comme le montre tableau 4. Ce modèle a donné une mauvaise performance pour toutes les classes.

Apprentissage					Test				
	P	D	N			P	D	N	
P	90	55	51	45,9%	P	19	20	15	35,2%
D	25	72	52	48,3%	D	7	9	11	33,3%
N	53	79	116	46,7%	N	15	23	28	42,4%
	53,6%	34,9%	52,9%	46,8%		46,3%	17,3%	51,8%	38,1%
F	49,4	40,5	49,6		F	40,0	22,8	46,6	

Tableau 4: Résultats obtenus appliquant l'analyse discriminante linéaire sur BDD_IBI

3.2.3 Machine à Vecteurs de Supports

Les résultats de SVM sont les suivants:

Dans l'ensemble d'apprentissage, ce modèle a correctement classé 83 enregistrements parmi 168 enregistrements pathologiques (49%), 124 enregistrements parmi 206 enregistrements douteux (60%) et 115 enregistrements parmi 219 enregistrements normaux (53%).

Dans l'ensemble de tests, parmi 41 enregistrements classés pathologiques par les médecins, nous avons obtenu 10 pathologiques, 19 douteux et 12 normaux; Parmi les 52 enregistrements classés douteux par les médecins, nous avons obtenu 11 pathologiques, 11 douteux et 33 normaux; Et parmi 54 enregistrements classés normalement par les médecins, nous avons obtenu 3 pathologiques, 29 douteux et 22 normaux. Ainsi, le rappel était 24,4% dans la classe pathologique, de 21,1% dans la classe douteuse et de 40,7% dans la classe normale. La précision a été de 47,6% dans la classe pathologique, 18,6% dans la classe douteuse et 32,8% dans la classe normale. L'exactitude a été 29,2% comme le montre tableau 5. Ce modèle a donné une performance mauvaise pour toutes les classes.

Apprentissage					Test				
	P	D	N			P	D	N	
P	83	25	31	59,7%	P	10	8	3	47,6%
D	45	124	73	51,2%	D	19	11	29	18,6%
N	40	57	115	54,2%	N	12	33	22	32,8%
	49,4%	60,2%	52,5%	54,3%		24,4%	21,1%	40,7%	29,2%
F	54,1	55,3	53,3		F	32,3	19,8	36,3	

Tableau 5: Résultats obtenus appliquant SVM sur BDD_IBI

3.2.4 Réseau de neurones artificiel

Le ANN construit comprend une couche de 14 entrées, une couche de sortie de 3 neurones et une couche cachée de 28 neurones (Figure 41).

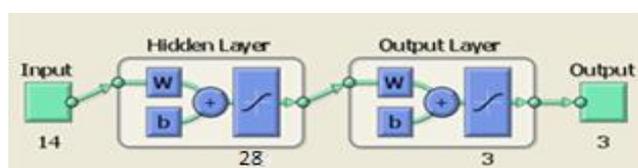


Figure 41: Réseau de neurone artificiel (ANN)

Les résultats du ANN sont les suivants :

Dans l'ensemble d'apprentissage, ce modèle a classé 152 enregistrements parmi 168 enregistrements pathologiques (90,5%), 191 enregistrements parmi 206 enregistrements douteux (92,7%) et 205 enregistrements parmi 219 enregistrements normaux (93,6%).

Dans l'ensemble test, parmi 41 enregistrements classés pathologiques par les médecins, nous avons obtenu 35 pathologiques, 1 douteux et 5 normaux; Parmi les 52 enregistrements classés douteux par les médecins, nous avons obtenu 0 pathologiques, 47 douteux et 5 normaux; Et parmi 55 enregistrements classés normalement par les médecins, nous avons obtenu 6 pathologiques, 17 douteux et 32 normaux. Ainsi, le rappel était 85,4% dans la classe pathologique, de 90,4% dans la classe douteuse et de 58,1% dans la classe normale. La précision a été de 85,4% dans la classe pathologique, 72,3% dans la classe douteuse et 76,2% dans la classe normale. L'exactitude a été 77% comme le montre tableau 6. Ce modèle a donné une performance moyenne pour les classes pathologiques et douteuses, mais mauvaise pour la classe normale.

Apprentissage					Test				
	P	D	N			P	D	N	
P	152	0	5	96,8%	P	35	0	6	85,4%
D	4	191	9	93,6%	D	1	47	17	72,3%
N	12	15	205	88,4%	N	5	5	32	76,2%
	90,5%	92,7%	93,6%	92,4%		85,4%	90,4%	58,1%	77,0%
F	93,5	93,1	90,9		F	85,4	80,3	65,9	

Tableau 6: Résultats obtenus appliquant ANN sur BDD_IBI

3.2.5 Arbre de décision

Les résultats de l'arbre de décision sont les suivants :

Dans l'ensemble d'apprentissage, ce modèle a correctement classé 168 enregistrements parmi 168 enregistrements pathologiques (100%), 188 enregistrements parmi 206 enregistrements douteux (91,3%) et 198 enregistrements parmi 219 enregistrements normaux (90,4%).

Dans l'ensemble de tests, parmi 41 enregistrements classés pathologiques par les médecins, nous avons obtenu 41 pathologiques, 0 douteux et 0 normaux; Parmi les 52 enregistrements classés douteux par les médecins, nous avons obtenu 2 pathologiques, 40 douteux et 10 normaux; Et parmi 55 enregistrements classés normale par les médecins, nous avons obtenu 2 pathologiques, 15 douteux et 38 normaux. Ainsi, le rappel était de 100% dans la classe pathologiques, 76,9% dans la classe douteux et 69,1% dans la classe normaux. La précision a été de 91,1% dans la classe pathologique, 72,7% dans la classe douteuse et 79,2% dans la classe normale. L'exactitude est de 80,4% comme le montre le tableau suivant. Ce modèle a donné une performance forte pour la classe pathologique mais moyenne pour les classes douteuse et normale.

Apprentissage					Test				
	P	D	N			P	D	N	
P	168	7	3	94,4%	P	41	2	2	91,1%
D	0	188	18	91,3%	D	0	40	15	72,7%
N	0	11	198	94,7%	N	0	10	38	79,2%
	100%	91,3%	90,4%	93,4%		100%	76,9%	69,1%	80,4%
F	97,1	91,3	92,5		F	95,3	74,7	73,8	

Tableau 7: Résultats obtenus appliquant l'arbre de décision sur BDD_IBI

3.2.6 Discussion des résultats

Le tableau 8 présente le résultat de notre étude comparative entre les 5 modèles utilisés. Pour la classe '*pathologique*', le meilleur résultat est obtenu par le modèle d'arbre de décision où la performance est forte (F_Mesure=95,3%), puis par ANN (F_Mesure=85,4%). Pour la classe douteuse, le meilleur résultat est obtenu par le modèle ANN (F_Mesure=80,3%), puis l'arbre de décision (F_Mesure=74,7). Pour la

classe normale, le meilleur résultat est obtenu par le modèle d'arbre de décision (F_Mesure=73,8%), puis avec ANN (F_Mesure=65,9%).

Méthode	P	D	N		P	D	N	Exactitude
RLM	43,9	50,34	22		39,4	51,3	21,4	42,5
ADL	49,4	40,5	49,6		40,0	22,8	46,6	38,1
SVM	54,1	55,3	53,3		32,3	19,8	36,3	29,2
ANN	93,5	93,1	90,9		85,4	80,3	65,9	77,0
DT	97,1	91,3	92,5		95,3	74,7	73,8	80,4

Tableau 8: comparaison des résultats des 5 méthodes sur BDD_IBI

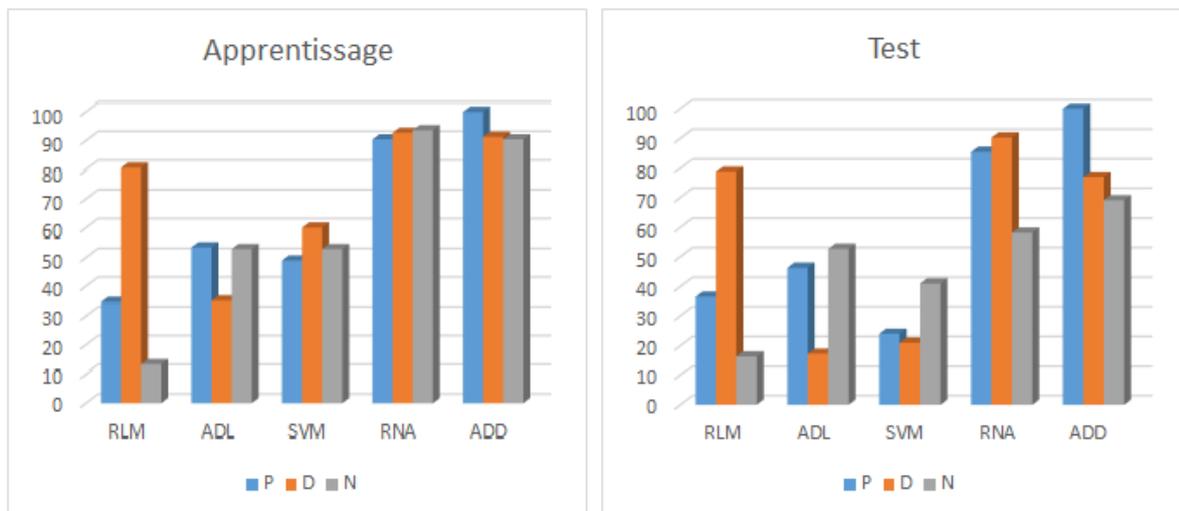


Figure 42 : comparaison des résultats sur BDD_IBI

Comme le montre tableau 8, les résultats obtenus à l'aide de LDA, MLR et SVM étaient mauvais. Les résultats obtenus à l'aide du réseau de neurones artificiels étaient moyens pour les classes Pathologique et Douteuse, mais mauvais pour la classe Normale. Les résultats obtenus à l'aide de l'arbre de décision ont été moyens pour les 3 classes.

Ce tableau comparatif montre que le réseau de neurone artificiel et l'arbre de décision ont donné les meilleurs résultats. La performance de la classe douteuse était meilleure dans ANN que dans l'arbre de décision et le contraire des classes pathologique et normale. En fait, les enfants classés douteux par les médecins ont une probabilité d'être soit normaux, soit malades, mais leur état n'était pas encore

clair au moment du diagnostic. En outre, l'état pathologique de ces enfants pourra se modifier après les 2 ans. Par contre, les enfants classés pathologiques par les médecins n'ont pas d'autre probabilité. Ainsi, la performance de la classe Pathologique est le plus important. L'arbre de décision a donné une meilleure performance de cette classe, ce qui signifie que les résultats obtenus à l'aide de l'arbre de décision étaient les meilleurs.

Dans ce travail, le réseau de neurones artificiels et l'arbre de décision ont donné des résultats moyens pour toutes les classes où la performance de la classe 'Pathologique' était meilleure que celle de la classe normale. Cela signifie que les caractéristiques extraites de l'EEG utilisées dans l'apprentissage en relation avec un pronostic pathologique sont meilleurs que ceux qui sont en relation avec un pronostic normal. Avec l'arbre de décision, nous avons trouvé parmi les 55 enfants classés normaux par les médecins, 2 pathologiques (3,6%), 15 douteux (27,3%) et 38 normaux (69,1%), et parmi les 52 enfants classés douteux par les médecins, 2 ont été trouvés pathologiques (3,8%), 40 douteux (76,9%) et 10 normaux (19,2%). Ainsi, l'erreur était de 30,9% dans la classe normale et de 23,1% dans la classe douteuse. D'après les médecins, une longue durée des IBI dans les enregistrements EEG est fortement corrélée avec un pronostic pathologique du prématuré. Par contre, les enregistrements ayant une courte durée dans les IBI, c'est-à-dire une longue durée dans les intervalles bouffés est corrélée avec un pronostic normal de l'enfant. Puisque la performance dans la classe normale dans notre travail était mauvaise, donc, les caractéristiques concernant les intervalles de bouffées étaient insuffisantes. Dans le travail suivant, nous allons utiliser la base d'apprentissage BDD_SEG dans laquelle les enregistrements ayant une amplitude faible sont séparés des enregistrements ayant une amplitude forte pour trouver les enfants classés normaux par les médecins, mais classés pathologiques et douteux par notre système.

3.3 Application de S_APP sur BDD_SEG.

Pour résoudre le problème rencontré dans la partie précédente, nous avons appliqué S_APP ayant BDD_SEG comme source sur les cinq modèles déjà présentés.

3.3.1 Régression linéaire multiple

Dans l'ensemble d'apprentissage, ce modèle a correctement classé 97 enregistrements parmi 168 enregistrements pathologique (57,7%), 117 enregistrements parmi 206 enregistrements douteux (56,8%) et 83 enregistrements parmi 219 enregistrements normaux (37,9%).

Dans l'ensemble de tests, parmi 41 enregistrements classés pathologiques par les médecins, nous avons obtenu 23 pathologiques et 12 douteux et 6 normaux. Parmi les 52 enregistrements classés douteux par les médecins, nous avons obtenu 4 pathologiques, 34 douteux et 14 normaux; Et parmi 54 enregistrements classés normaux par les médecins, nous avons obtenu 4 pathologiques, 31 douteux et 19 normaux. Ainsi, le rappel a été de 57,7% (23/41) dans la classe pathologique, 65,4% (34/52) dans la classe douteuse et 35,2% (19/54) dans la classe normale. La précision a été de 74,2% dans la classe pathologique, 44,1% dans la classe douteuse et 48,7% dans la classe normale. L'exactitude a été de 51,7% comme le montre le tableau 9. Ce modèle a donné une mauvaise performance dans toutes les classes.

Apprentissage					Test				
	P	D	N			P	D	N	
P	97	35	10	68,3%	P	23	4	4	74,2%
D	63	117	126	38,2%	D	12	34	31	44,1%
N	8	54	83	57,2%	N	6	14	19	48,7%
	57,7%	56,8%	37,9%	50,1%		57,7%	65,4%	35,2%	51,7%
F	71,1	40,9	52,6		F	64,9	52,7	40,9	

Tableau 9: Résultats obtenus appliquant la régression linéaire multiple sur BDD_SEG

3.3.2 Analyse discriminante linéaire

Dans l'ensemble d'apprentissage, ce modèle a correctement classé 108 enregistrements parmi 168 enregistrements pathologiques (64,3%), 108 enregistrements parmi 206 enregistrements douteux (52,4%) et 138 enregistrements parmi 219 enregistrements normaux (63%).

Dans l'ensemble de tests, parmi 41 enregistrements classés pathologiques par les médecins, nous avons obtenu 31 pathologiques, 5 douteux et 5 normaux; Parmi les 52 enregistrements classés douteux par les médecins, nous avons obtenu 9 pathologiques, 23 douteux et 20 normaux; Et parmi 55 enregistrements classés normaux par les médecins, nous avons obtenu 6 pathologiques, 12 douteux et 36 normaux. Ainsi, le rappel était de 75,6% dans la classe pathologique, 44,2% dans la classe douteuse et 66,6% dans la classe normale. La précision a été de 67,4% dans la classe pathologique, 57,5% dans la classe douteuse et 59,0% dans la classe normale. L'exactitude a été 61,2% comme le montre tableau 10. Ce modèle a donné une mauvaise performance dans toutes les classes.

Apprentissage					Test				
	P	D	N			P	D	N	
P	108	31	15	70,1%	P	31	9	6	67,4%
D	18	108	66	56,2%	D	5	23	12	57,5%
N	42	67	138	55,9%	N	5	20	36	59,0%
	64,3%	52,4%	63,0%	59,7%		75,6%	44,2%	66,6%	61,2%
F	67,1	54,2	59,2		F	71,3	50,0	62,6	

Tableau 10: Résultats obtenus appliquant l'analyse discriminante linéaire sur BDD_SEG

3.3.3 Machine à Vecteurs de Supports

En appliquant les SVM sur notre ensemble de données, nous avons trouvé les résultats suivants:

Dans l'ensemble d'apprentissage, ce modèle a correctement classé 118 enregistrements parmi 168 enregistrements pathologiques (70,2%), 127 enregistrements parmi 206 enregistrements douteux (61,6%) et 159 enregistrements parmi 219 enregistrements normaux (72,6%).

Dans l'ensemble de tests, parmi 41 enregistrements classés pathologiques par les médecins, nous avons obtenu 24 pathologiques, 5 douteux et 12 normaux; Parmi les 52 enregistrements classés douteux par les médecins, nous avons obtenu 3

pathologiques, 33 douteux et 16 normaux; Et parmi 54 enregistrements classés normalement par les médecins, nous avons obtenu 0 pathologiques, 18 douteux et 36 normaux. Ainsi, le rappel était de 58,5% pour la classe pathologique, de 63,5% dans la classe douteuse et de 66,6% dans la classe normale. La précision a été de 88,9% dans la classe pathologique, 58,9% dans la classe douteuse et 56,2% dans la classe normale. L'exactitude a été 63,3% comme le montre tableau11 Ce modèle a donné une mauvaise performance dans toutes les classes.

Apprentissage					Test				
	P	D	N			P	D	N	
P	118	3	11	89,4%	P	24	3	0	88,9%
D	11	127	49	67,9%	D	5	33	18	58,9%
N	39	76	159	58,0%	N	12	16	36	56,2%
	70,2%	61,6%	72,6%	68,1%		58,5%	63,5%	66,6%	63,3%
F	78,6	64,6	64,5		F	70,6	61,1	61,0	

Tableau 11: Résultats obtenus appliquant SVM sur BDD_SEG

3.3.4 Réseau de neurones artificiel

Le ANN construit comprend une couche de 26 entrées, une couche de sortie avec 3 neurones et une couche cachée avec 52 neurones.

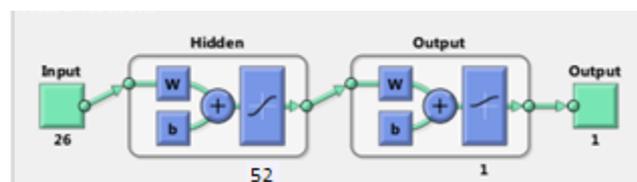


Figure 43: Réseau de neurone artificiel sur BDD_SEG

En appliquant le ANN sur notre ensemble de données, nous avons trouvé les résultats suivants:

Dans l'ensemble d'apprentissage, ce modèle a correctement classé 168 enregistrements parmi 168 enregistrements pathologiques (100%), 195 enregistrements parmi 206 enregistrements douteux (95%) et 210 enregistrements parmi 219 enregistrements normaux (96%).

Dans l'ensemble de tests, parmi 41 enregistrements classés pathologiques par les médecins, nous avons obtenu 41 pathologiques, 0 douteux et 0 normaux; Parmi les 52 enregistrements classés douteux par les médecins, nous avons obtenu 0 pathologiques, 45 douteux et 7 normaux; Et parmi 54 enregistrements classés normaux par les médecins, nous avons obtenu 11 pathologiques, 5 douteux et 38 normaux. Ainsi, le rappel est de 100% dans la classe pathologique, de 86,5% dans la classe douteuse et de 70,4% dans la classe normale. La précision est de 78,8% dans la classe pathologique, 90,0% dans la classe douteuse et 84,4% dans la classe normale. L'exactitude est de 84,3% comme le montre le tableau 12. Ce modèle a donné une performance moyenne dans toutes les classes.

Apprentissage					Test				
	P	D	N			P	D	N	
P	168	0	1	99,4%	P	41	0	11	78,8%
D	0	195	8	96,1%	D	0	45	5	90,0%
N	0	11	210	95,0%	N	0	7	38	84,4%
	100%	94,7%	95,9%	96,7%		100%	86,5%	70,4%	84,3%
F	99,7	96,1	95		F	88,1	88,2	76,8	

Tableau 12: Résultats obtenus appliquant ANN sur BDD_SEG

3.3.5 Arbre de décision

En appliquant l'arbre de décision sur BDD_SEG, nous avons trouvé les résultats suivants:

Dans l'ensemble d'apprentissage, ce modèle a correctement classé 168 enregistrements parmi 168 enregistrements pathologiques (100%), 187 enregistrements parmi 206 enregistrements douteux (91%) et 211 records parmi 219 enregistrements normaux (96%).

Dans l'ensemble de test, parmi 41 enregistrements classés pathologiques par les médecins, nous avons obtenu 41 pathologiques, 0 douteux et 0 normaux. Parmi les 52 enregistrements classés douteux par les médecins, nous avons obtenu 5

pathologiques, 40 douteux et 7 normaux; Et parmi 55 enregistrements classés normaux par les médecins, nous avons obtenu 2 pathologiques, 8 douteux et 44 normaux. Ainsi, le rappel est de 100% pour la classe pathologique, 76,9% pour la classe douteuse et 81,5% pour la classe normale. La précision est de 85,4% dans la classe pathologique, 83,3% dans la classe douteuse et 86,3% dans la classe normale. L'exactitude est de 85% comme le montre le tableau 13. Ce modèle a donné une forte performance pour la classe pathologique mais moyenne pour les classes douteuse et normale.

Apprentissage					Test				
	P	D	N			P	D	N	
P	168	3	1	97,6%	P	41	5	2	85,4%
D	0	187	7	96,4%	D	0	40	8	83,3%
N	0	16	211	92,9%	N	0	7	44	86,3%
	100%	90,7%	96,3%	95,4%		100%	76,9%	81,5%	85,0%
F	98,8	93,5	94,6		F	92,1	80,0	83,8	

Tableau 13: Résultats obtenus appliquant l'arbre de décision sur BDD_SEG

3.3.6 Discussion des résultats

Le tableau suivant illustre la progression de F_Mesure de toutes les méthodes utilisées dans les deux bases d'apprentissage BDD_IBI et BDD_SEG :

Méthode	BDD	Apprentissage			Test		
		P	D	N	P	D	N
RLM	BDD_IBI	43,9	50,3	22,0	39,4	51,3	21,4
	BDD_SEG	71,1	40,9	52,6	64,9	52,7	40,9
ADL	BDD_IBI	49,4	40,5	49,6	40,0	22,8	46,6
	BDD_SEG	67,1	54,2	59,2	71,3	50	62,6
SVM	BDD_IBI	54,1	55,3	53,3	32,3	19,8	36,3
	BDD_SEG	78,6	64,6	64,5	70,6	61,1	61
ANN	BDD_IBI	93,5	93,1	90,9	85,4	80,3	65,9
	BDD_SEG	99,7	96,1	95	88,1	88,2	76,7
DT	BDD_IBI	97,1	91,3	92,5	95,3	74,7	73,8
	BDD_SEG	98,8	93,5	94,6	92,1	80,0	83,8

Tableau 14: comparaison des résultats des 5 modèles sur BDD_IBI et BDD_SEG

D'autre part, on remarque que la segmentation des bouffées en faible moyenne et forte a permis de progresser considérablement le rappel dans toutes les méthodes pour arriver à 100% dans ANN et DT. C'est-à-dire, trouver les enfants classés pathologiques par les médecins ayant une faible amplitude dans leur enregistrement EEG et qui étaient classés normaux et douteux avant la segmentation. Ce qui vérifie la théorie des médecins qu'il existe une relation entre l'amplitude faible dans le signal EEG et les pronostics anormaux du bébé. D'autre part, la séparation des enregistrements ayant une amplitude forte des autres enregistrements a causé une progression dans le rappel de la classe « normal » pour toutes les méthodes. Ceci vérifie la théorie des médecins selon laquelle il existe une relation entre l'amplitude forte dans le signal EEG et les pronostics normaux du bébé. La classe douteuse, qui va être plus tard normale ou pathologique est moins importante que les deux autres classes.

Concernant les modèles utilisés, on remarque que la performance dans RLM, ADL et SVM était mauvaise dans les deux bases d'apprentissage. Ce qui vérifie que ces modèles ne sont pas convenables pour un ensemble de données non linéaire pareil à notre cas. Dans la suite de notre travail nous allons nous limiter à l'utilisation des modèles ANN et DT.

3.4 Choix des seuils dans la segmentation.

La progression dans le rappel de la classe normale reste toujours insuffisante, donc après une discussion avec des neuro-pédiatres, nous avons essayé une autre série de valeur de seuil dans la segmentation :

- Seuil d'aplatissement inférieur à $10\mu\text{v}$.
- Activité faible comprise entre $10\mu\text{v}$ et $25\mu\text{v}$.
- Activité moyenne: entre $25\mu\text{v}$ et $50\mu\text{v}$.
- Activité forte supérieure à $50\mu\text{v}$.

Nous avons indiqué dans le premier chapitre qu'il existe dans le signal EEG des artefacts causés soit par le clin d'œil, soit par le battement du cœur qui apparaissent sous forme de bouffées d'amplitude forte. Normalement, ces bouffées ont une durée très courte. Nous avons modifié les seuils dans l'analyseur SegEEG et nous avons éliminé les segments inférieurs à 2s. En l'appliquant sur les 740 EEG, nous avons obtenu une nouvelle version de BDD_SEG que nous avons appelé BDD_SEG2.

En appliquant S_APP sur BDD_SEG2, le ANN produit de meilleurs résultats.

Dans l'ensemble d'apprentissage, ce modèle a correctement classé 157 enregistrements parmi 168 enregistrements pathologique (93%), 198 enregistrements parmi 206 enregistrements douteux (96%) et 214 records parmi 219 enregistrements normaux (98%).

Dans l'ensemble test, parmi 41 enregistrements classés pathologiques par les médecins, nous avons obtenu 38 pathologiques, 2 douteux et 1 normal; Parmi les 52 enregistrements classés douteux par les médecins, nous avons obtenu 1 pathologique, 48 douteux et 3 normaux; Et parmi 55 enregistrements classés normaux par les médecins, nous avons obtenu 5 pathologiques, 8 douteux et 41 normaux. Ainsi, le rappel était de 93% pour la classe pathologique, 92% pour la classe douteuse et 76% pour la classe normale. La précision a été de 86,4% dans la classe pathologique, 82,7% dans la classe douteuse et 91,1% dans la classe normale. L'exactitude a été 86,4% comme le montre le tableau 15. Ce modèle possède donc une forte performance pour la classe « pathologique » et la classe « douteux », mais moyenne pour la classe « normal ».

Apprentissage					Test				
	P	D	N			P	D	N	
P	157	2	4	96,3%	P	38	1	5	86,4%
D	7	198	1	96,1%	D	2	48	8	82,7%
N	4	6	214	95,5%	N	1	3	41	91,1%
	93,4%	96,1%	97,7%	95,9%		92,7%	92,3%	75,9%	86,4%
F	94,8	96,1	96,6		F	89,4	87,2	82,8	

Tableau 15: résultats obtenus après le changement des seuils utilisant ANN sur BDD_SEG

En comparant ces résultats avec les résultats de S_APP sur BDD_SEG, on constate que le rappel a progressé pour les classes normal et douteux mais s'est dégradé pour la classe pathologique. Ceci implique qu'il y a des attributs qui perturbent l'apprentissage dans BDD_SEG2. Le tableau 16 illustre la comparaison des résultats :

Méthode	BDD	Apprentissage			Test		
		P	D	N	P	D	N
ANN	BDD_SEG	100	94,7	95,9	100	86,5	70,4
	BDD_SEG2	93,4	96,1	97,7	92,7	92,3	75,9

Tableau 16: comparaison des résultats des 2 seuils utilisant ANN sur BDD_SEG

3.5 Proposition des caractéristiques utiles du signal EEG

La tâche suivante consiste à trouver dans le signal EEG les segments qui donnent une meilleure performance dans l'apprentissage. Pour ce faire nous avons segmenté l'amplitude du signal EEG en 8 segments qui sont les suivants:

- b1 : <math> < 10 \mu v </math>
- b2 : $10 \mu v - 20 \mu v$
- b3 : $20 \mu v - 30 \mu v$
- b4 : $30 \mu v - 40 \mu v$
- b5 : $40 \mu v - 50 \mu v$
- b6 : $50 \mu v - 75 \mu v$
- b7 : $75 \mu v - 100 \mu v$
- b8 : $> 100 \mu v$

Nous avons créé un nouvel analyseur que nous avons appelé Seg_Test pour détecter les intervalles de ces segments dans les enregistrements EEG de BDD_SEG. Nous avons obtenu une nouvelle base d'apprentissage sur laquelle nous avons créé l'arbre de décision (Figure 44).

On constate que cet arbre commence par les intervalles d'amplitude forte et faible (b8, b2, b3 et b1) et se termine par les intervalles d'amplitude moyenne. Donc les variables concernant les activités moyennes sont les moins importantes dans la décision. En fait, ces variables ont une intersection d'une part avec les enregistrements d'activité faibles, et d'autre part avec ceux qui ont une activité forte. Ce qui peut causer une perturbation dans l'apprentissage.

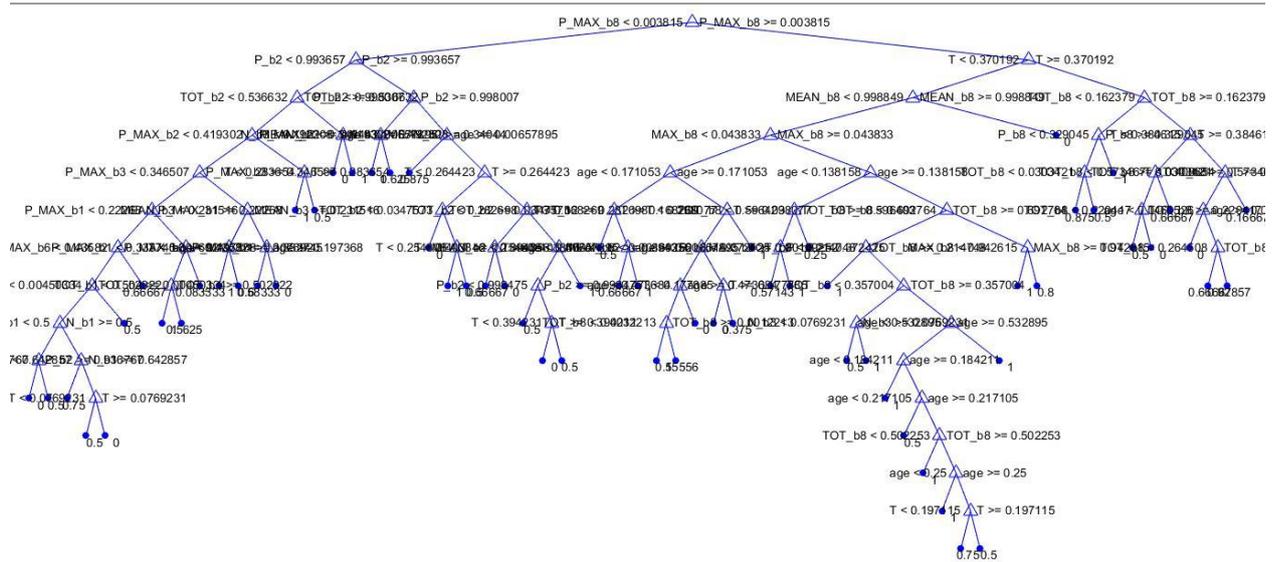


Figure 44: Arbre de décision

Donc nous avons effacé de BDD_SEG2 les 6 attributs concernant les activités moyennes, et la nouvelle version de BDD_SEG2 que nous avons appelé BDD_SEG3 est formée de 740 instances et de 20 variables qui sont :

- les 6 variables détectées par SegEEG sur les intervalles d'aplatissement inférieur à 10µv.
- les 6 variables détectées par SegEEG sur les intervalles d'activité faible comprise entre 10 µv et 25µv.
- les 6 variables détectées par SegEEG sur les intervalles d'activité forte supérieure à 50 µv.
- L'âge gestationnel (AG) du bébé.
- Le jour d'enregistrement de l'EEG.

En appliquant S_APP sur BDD_SEG3, nous obtenons avec ANN les résultats suivants.

Nous avons obtenu dans l'ensemble d'apprentissage un rappel de 100% pour la classe normale, 88,3% pour la classe douteux et 100% pour la classe pathologiques. Et dans la base de test nous avons obtenu un rappel de 87% pour la classe normale, 80,7% dans la classe douteux et 100% dans la classe pathologiques, ainsi qu'une précision de 87,2% dans la classe pathologique, 97,7% dans la classe douteuse et 82,4% dans la classe normale. L'exactitude est de 88,4% comme le montre le tableau suivant:

Apprentissage					Test				
	P	D	N			P	D	N	
P	168	0	0	100%	P	41	0	6	87,2%
D	0	182	0	100%	D	0	42	1	97,7%
N	0	24	219	90,1%	N	0	10	47	82,4%
	100%	88,3%	100%	95,6%		100%	80,7%	87%	88,4%
F	100	93,8	94,8		F	93,2	88,4	84,6	

Tableau 17: résultats obtenus utilisant ANN sur BDD_SEG ayant 20 attributs

Les résultats de l'arbre de décision sont les suivants :

Nous avons obtenu dans l'ensemble d'apprentissage un rappel de 99% des enregistrements normaux, et 95% des enregistrements douteux et 95% des enregistrements pathologiques. Et dans l'ensemble de test, le rappel était 76% pour la classe normale, 85% dans la classe douteuse et 100% dans la classe pathologique. La précision a été de 80,4% dans la classe pathologique, 93,6% dans la classe douteuse et 63,6% dans la classe normale. L'exactitude a été 85,7% comme l'indique le tableau suivant:

Apprentissage					Test				
	P	D	N			P	D	N	
P	167	1	2	98,2%	P	41	0	10	80,4%
D	1	195	10	94,6%	D	0	44	3	93,6%
N	0	10	207	95,3%	N	0	8	41	83,7%
	99%	94,6%	94,5%	95,9%		100%	84,6%	75,9%	85,7%
F	98,6	94,6	94,9		F	89,1	88,9	75,6	

Tableau 18: résultats obtenus utilisant l'arbre de décision sur BDD_SEG ayant 20 attributs

Enfin le tableau suivant présente une comparaison du rappel entre l'arbre de décision et le ANN en appliquant S_APP sur BDD_SEG3:

Méthode	BDD	Apprentissage			Test		
		P	D	N	P	D	N
ANN	BDD_SEG3	100%	88,3%	100%	100%	80,7%	87%
DT	BDD_SEG3	99%	94,6%	94,5%	100%	84,6%	75,9%

Tableau 19: comparaison des résultats de ANN et l'arbre de décision sur BDD_SEG

3.6 Conclusion.

Les attributs de BDD_SEG3 sont les suivants :

- (1) Nombre de période d'aplatissement : N_B_ IBI
- (2) Temps cumulé d'aplatissement : TOT_IBI
- (3) Pourcentage Temps cumulé d'aplatissement : P_IBI
- (4) Plus long aplatissement : MAX_IBI
- (5) Pourcentage du plus long aplatissement : P_MAX_IBI
- (6) Temps moyen d'aplatissement : MEAN_IBI
- (7) Nombre de période d'activité faible : N_B_ faible
- (8) Temps cumulé d'activité faible : TOT_B_ faible
- (9) Pourcentage Temps cumulé d'activité faible: P_B_ faible
- (10) Plus longue activité faible: MAX_B_ faible
- (11) Pourcentage de la plus longue activité faible : P_MAX_faible
- (12) Temps moyen d'activité faible: MEAN_B_ faible
- (13) Nombre de période d'activité forte : N_B_ fort
- (14) Temps cumulé d'activité forte: TOT_B_ fort
- (15) Pourcentage Temps cumulé d'activité forte: P_B_ fort
- (16) Plus longue activité forte: MAX_B_ fort
- (17) Pourcentage de la plus longue activité forte : P_MAX_B_ fort
- (18) Temps moyen d'activité forte : MEAN_B_ fort
- (19) Jour de l'enregistrement EEG: OLD
- (20) Age de conception en semaine: AG_EEG
- (21) Le diagnostic : Class

Les résultats obtenus montrent que les attributs formés des 20 variables définies dans BDD_SEG3 ont donnés une progression remarquable dans le rappel de toutes les classes dans l'apprentissage en utilisant le réseau de neurones. Nous avons pu

améliorer le rappel dans la classe normale de 58,2% à 87% et dans la classe pathologique de 85,5% à 100%. Cependant le rappel de la classe douteuse reste à 80,7%. Le tableau suivant résume la progression du rappel dans les différentes bases de données.

Source de S_APP	Nb d'attributs	Apprentissage			Test			exactitude
		P	D	N	P	D	N	
BDD_IBI	14	90,1	93	93,6	85,5	90,3	58,2	77%
BDD_SEG	26	83,7	90,1	96,7	85,5	83,9	68,5	84,3%
BDD_SEG2	26	93,4	96	97,7	92,9	92	75,9	86,4%
BDD_SEG3	20	100	88,4	100	100	80	86,8	88,4%

Tableau 20: Progression de la performance pour ANN

En effet, les diagnostics offerts par les médecins dans BDD_SEG3 ont été donnés à deux ans après la naissance. Mais plus tard, ils peuvent être modifiés. Par suite, on peut déduire que :

- Parmi les 53 enfants classés normaux par les médecins, 6 enfants peuvent être pathologiques plus tard et un douteux.
- Parmi les 50 enfants classés douteux par les médecins, 10 enfants peuvent être pathologiques plus tard.

Donc, On peut déduire que ces résultats peuvent être une prévision du devenir du nouveau-né prématuré même plus tard après deux ans de la naissance. Par suite le rappel peut être mieux que 87% dans la classe normale et mieux que 81% dans la classe douteuse, puisque ce système peut donner une prévision après plus que deux ans pour les 19% des enregistrements classés douteux et les 13% des enregistrements classés normaux par les médecins. Pour vérifier cette conclusion, un suivi des enfants concerné est nécessaire.

4 Chapitre 4: Analyse des Données Corrélatives

4.1	Introduction.....	92
4.2	Corrélation produit des moments de Pearson.....	92
4.3	Matrice de corrélation.....	93
4.4	Détermination des caractéristiques pertinentes du signal EEG.....	94
4.5	Conclusion.....	98

4.1 Introduction

Dans ce chapitre, nous présentons une analyse des corrélations entre les 20 attributs pour trouver des séries d'attributs redondants et éliminer parmi eux ceux qui sont moins importants, et par suite réduire leur nombre. Pour réaliser ce travail, nous allons calculer la corrélation entre tous les attributs pour trouver leur matrice de corrélation. Ensuite, nous allons choisir des séries d'attributs ayant une corrélation supérieure à 90% pour trouver les attributs qui donnent des résultats proches. Puis parmi ces attributs, nous allons calculer la corrélation entre chacun d'eux et la classe pour déterminer celui qui est le moins important et ainsi l'éliminer du modèle de classification. Enfin nous allons éliminer les attributs correspondants pour réduire le nombre d'attributs de BDD_SEG3 et former une nouvelle base d'apprentissage.

4.2 Corrélation produit des moments de Pearson

L'analyse de corrélation est une méthode d'évaluation statistique utilisée pour étudier la force d'une relation entre deux variables numériquement mesurées (par exemple, hauteur et poids) [86]. Ce type particulier d'analyse est utile lorsqu'un chercheur veut établir s'il existe des liens possibles entre les variables. Si la corrélation est trouvée entre deux variables, cela signifie que lorsqu'il y a un changement systématique dans une variable, il y a aussi un changement systématique dans l'autre. S'il existe une corrélation, selon les valeurs numériques mesurées, elle peut être positive ou négative.

- Une corrélation positive existe si une variable augmente simultanément avec l'autre, c'est-à-dire que les valeurs numériques élevées d'une variable sont liées aux valeurs numériques élevées de l'autre.
- Une corrélation négative existe si une variable diminue lorsque l'autre augmente, c'est-à-dire que les valeurs numériques élevées d'une variable se rapportent aux valeurs numériques faibles de l'autre.

Le coefficient produit des moments de Pearson est la mesure de la corrélation qui varie entre +1 et -1. +1 indique la corrélation positive la plus forte possible, et -1 indique la plus forte corrélation négative possible. Par conséquent, plus le coefficient est proche de l'un de ces nombres, plus la corrélation des données qu'il représente est forte. Sur cette échelle, 0 indique aucune corrélation, donc des valeurs proches de zéro mettent en évidence une corrélation plus faible que celles qui sont plus proches de + 1 / -1.

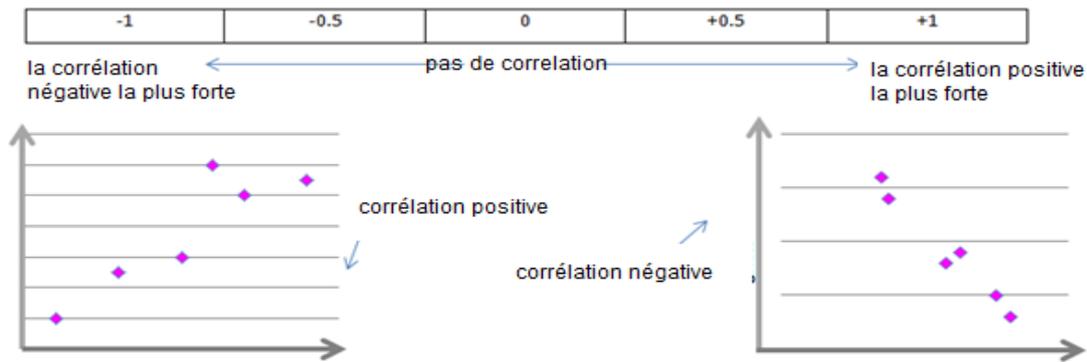


Figure 45: corrélation positive et négative

La formule de la corrélation produit des moments de Pearson est la suivante [87]:

$$\text{correl}(x, y) = \frac{\sum((x - \bar{x}) \times (y - \bar{y}))}{\sqrt{\sum(x - \bar{x})^2 \times \sum(y - \bar{y})^2}}$$

4.3 Matrice de corrélation

Dans la plupart des études, nous avons beaucoup plus de deux variables. Disons que nous avons une étude avec 10 variables de niveau d'intervalle et nous voulons estimer les relations entre toutes les paires possibles de ces variables. Voici le résultat du calcul des corrélations entre ces variables:

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10
C1	1,000									
C2	0,274	1,000								
C3	-0,134	-0,269	1,000							
C4	0,201	-0,153	0,075	1,000						
C5	-0,129	-0,166	0,278	-0,011	1,000					
C6	-0,095	0,280	-0,348	-0,378	-0,009	1,000				
C7	0,171	-0,122	0,288	0,086	0,193	0,002	1,000			
C8	0,219	0,242	-0,380	-0,227	-0,551	0,324	-0,082	1,000		
C9	0,518	0,238	0,002	0,082	-0,015	0,304	0,347	-0,013	1,000	
C10	0,299	0,568	0,165	-0,122	-0,106	-0,169	0,243	0,014	0,35	1,000

Figure 46: matrice de corrélation

Ce type de tableau s'appelle une matrice de corrélation. Il repère les noms des variables (C1-C10) dans la première colonne et sur la première ligne. La diagonale d'une matrice de corrélation se compose toujours de 1. C'est parce que ce sont les corrélations entre chaque variable et elle-même (une variable est toujours

parfaitement corrélée avec elle-même). Ce programme statistique ne montre que le triangle inférieur de la matrice de corrélation. Dans chaque matrice de corrélation, il existe deux triangles qui sont les valeurs en-dessous et à gauche de la diagonale (triangulaire inférieur) et au-dessus et à droite de la diagonale (triangulaire supérieur). Il n'y a aucune raison d'imprimer les deux triangles car les deux triangles d'une matrice de corrélation sont toujours des images miroir les unes des autres (la corrélation de la variable x avec la variable y est toujours égale à la corrélation de la variable y avec la variable x).

Pour localiser la corrélation pour chaque paire de variables, il faut trouver la valeur dans la table pour l'intersection de ligne et de colonne pour ces deux variables.

Autres corrélations.

Cependant, il existe une grande variété d'autres types de corrélations pour d'autres circonstances. Par exemple, la corrélation de commande de rang de Spearman, la corrélation point-biserial ou la corrélation de rang de Kendall...

4.4 Détermination des caractéristiques pertinentes du signal EEG

Pour trouver les attributs redondants, nous avons calculé la matrice de corrélation utilisant la théorie du produit des moments de Pearson sur les 20 variables de BDD_SEG.

	att1	att2	att3	att4	att5	att6	att7	att8	att9	att10	att11	att12	att13	att14	att15	att16	att17	att18	att19	att20
att1	1,0																			
att2	1,0	1,0																		
att3	0,9	1,0	1,0																	
att4	0,8	0,8	0,8	1,0																
att5	0,8	0,8	0,9	0,9	1,0															
att6	0,8	0,8	0,8	0,9	0,9	1,0														
att7	0,5	0,4	0,4	0,4	0,4	0,4	1,0													
att8	0,1	0,1	0,1	0,2	0,1	0,2	0,7	1,0												
att9	0,2	0,1	0,1	0,2	0,2	0,3	0,8	0,9	1,0											
att10	0,2	0,1	0,1	0,2	0,1	0,2	0,5	0,8	0,8	1,0										
att11	0,2	0,1	0,1	0,2	0,2	0,3	0,5	0,7	0,8	0,9	1,0									
att12	0,0	0,0	0,0	0,0	0,0	0,1	0,3	0,7	0,7	0,9	0,8	1,0								
att13	0,0	0,0	0,0	0,0	0,0	0,0	0,2	0,1	0,1	-0,1	-0,1	-0,1	1,0							
att14	-0,3	-0,3	-0,3	-0,3	-0,3	-0,4	-0,7	-0,7	-0,7	-0,6	-0,6	-0,5	-0,3	1,0						
att15	-0,4	-0,4	-0,4	-0,4	-0,4	-0,4	-0,8	-0,7	-0,8	-0,6	-0,7	-0,5	-0,3	0,9	1,0					
att16	-0,3	-0,3	-0,3	-0,3	-0,3	-0,3	-0,6	-0,6	-0,6	-0,5	-0,5	-0,4	-0,4	0,9	0,8	1,0				
att17	-0,3	-0,3	-0,3	-0,3	-0,3	-0,4	-0,7	-0,6	-0,7	-0,5	-0,6	-0,4	-0,5	0,9	0,9	0,9	1,0			
att18	-0,2	-0,2	-0,2	-0,2	-0,2	-0,2	-0,5	-0,4	-0,4	-0,4	-0,4	-0,3	-0,5	0,7	0,6	0,9	0,8	1,0		
att19	-0,3	-0,2	-0,3	-0,3	-0,3	-0,3	-0,4	-0,4	-0,4	-0,4	-0,4	-0,4	0,0	0,4	0,4	0,4	0,3	0,3	1,0	
att20	-0,3	-0,2	-0,3	-0,2	-0,2	-0,2	-0,2	-0,1	-0,1	0,1	0,1	0,1	0,0	0,1	0,1	0,0	0,1	0,0	-0,3	1,0

Figure 47: matrice de corrélation entre les 20 attributs de BDD_SEG

Les attributs ayant une corrélation supérieure à 90% sont les suivants :

{(1,2); (1,3); (2,3); (4,5); (4,6); (8,9); (10,11); (14,15); (16,17); (14,16)}

Les attributs ayant une corrélation entre 80% et 90% sont les suivants :

{(1,4); (2,4); (3,4); (3,5); (2,6); (3,6); (5,6); (8,10); (9,10); (9,12); (10,12); (15,16); (15,17); (14,17); (16,18)}

On va se limiter à une corrélation supérieure à 90% pour former des séries d'attributs sur lesquelles on va faire des tests pour choisir ceux qui peuvent être éliminés pour réduire le nombre des attributs dans BDD_SEG.

On constate que parmi les attributs ayant une corrélation supérieure à 90% il y a une corrélation entre attribut1 et attribut2, entre attribut1 et attribut3 et entre attribut2 et attribut3, donc attribut1, attribut2, et attribut3 forment une série.

Serie1 : N_IBI, T_IBI et P_IBI

De même, il y a une corrélation entre attribut4 et attribut5 et entre attribut4 et attribut6, donc attribut4, attribut5, et attribut6 forment une série.

Serie2 : MAX_IBI, P_MAX_IBI et MEAN_IBI

Il y a une corrélation entre attribut8 et attribut9, donc attribut8 et attribut9 forment une série.

Serie3 : TOT_B_Faible et P_B_Faible

Il y a une corrélation entre attribut10 et attribut11, donc attribut10 et attribut11 forment une série.

Serie4 : MAX_B_Faible et P_MAX_B_Faible

Il y a une corrélation entre attribut14 et attribut15, entre attribut14 et attribut16 et entre attribut16 et attribut17, donc attribut14, attribut15, attribut16 et attribut17 forment une série.

Serie5 :TOT_B_Fort, P_B_Fort, MAX_B_Fort et P_MAX_B_Fort

Puis nous avons calculé la corrélation de chacun de ces attributs avec la classe pour trouver que:

Parmi les attributs de serie1 : N_IBI a la corrélation minimale,

Parmi les attributs de serie2 : MAX_IBI a la corrélation minimale.

Parmi les attributs de serie3 : P_B_Faible a la corrélation minimale.

Parmi les attributs de serie4 : P_MAX_B_Faible a la corrélation minimale.

Parmi les attributs de serie5 : TOT_B_Fort a la corrélation minimale.

Donc ces 5 attributs peuvent être éliminés de BDD_SEG3. Nous avons ensuite déterminé tous les combinaisons de ces cinq attributs et appliqué S_APP sur BDD_SEG3 en éliminant à chaque fois les attributs correspondants.

Les meilleurs résultats ont été obtenus par ANN sur BDD_SEG3 (20 attributs). Le rappel était dans l'ensemble d'apprentissage de 100% dans la classe normale, de 88% dans la classe douteux et de 100% dans la classe pathologiques. Dans l'ensemble de test, il était de 87% dans la classe normale, de 81% dans la classe douteuse et de 100% dans la classe pathologique. Parmi les tests que nous avons effectués nous allons présenter ceux qui ont donnés des résultats similaires ou meilleurs.

Le tableau suivant présente les résultats obtenus, « N° Attribut enlevés » sont les numéros des attributs enlevés de BDD_SEG et « NB itérations » est le nombre d'itérations effectué durant l'apprentissage sachant que le nombre maximal est de 1000 ou lorsque la valeur de MSE (mean square error) est inférieure à 0,05 :

N° Attribut enlevés	Nb itérations	Apprentissage			Test		
		P	D	N	P	D	N
1, 14, 11, 16	1000	100	99	99,5	100	98	81,1
11, 14, 16	920	100	96	100	100	96	83
1, 2, 9	632	100	94	100	100	88	84,9
1, 2, 4, 14, 16	1000	100	96	100	100	86	88,7
1, 2, 14, 16	1000	100	95	100	100	96	88,7
2, 16	1000	100	99,5	100	100	90	88,7
4, 9, 14	724	100	92	100	100	84	90,6
1, 11, 16	735	100	96,5	100	100	90	90,6

Tableau 21: comparaison des résultats des différentes séries utilisant ANN sur BDD_SEG

On constate que dans la classe pathologique le rappel est de 100% dans toutes les séries. D'autre part, les séries qui ont données le meilleur rappel dans la classe douteuse n'avaient pas une meilleure performance dans la classe normale. Nous avons déjà expliqué que la classe normale est plus importante que la classe douteuse. Par suite, le meilleur résultat obtenu était en enlevant attribut1, attribut11 et attribut16 qui sont N_IBI, P_MAX_B_Faible et MAX_B_Fort respectivement. Par suite, en enlevant ces trois attributs de BDD_SEG3 nous avons obtenus une nouvelle base d'apprentissage que nous avons appelés BDD_COR. Les résultats de l'application de S_APP sur BDD_COR sont les suivants :

Training set					Test set				
	P	D	N		P	D	N		
P	168	0	0	100%	P	41	0	3	93,1%
D	0	199	0	100%	D	0	47	2	95,9%
N	0	7	219	96,9%	N	0	5	49	90,7%
	100%	96,6%	100%	98,8%		100%	90,3%	90,7%	93,2%

Tableau 22: résultats obtenus utilisant l'arbre de décision sur BDD_SEG ayant 17 attributs

Le ANN construit ayant un nombre de neurones cachés qui est du double du nombre de variables d'entrées est le suivant :

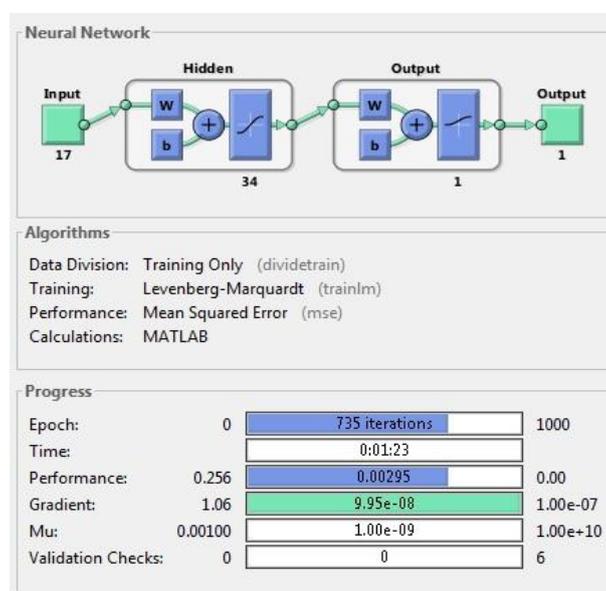


Figure 48: Réseau de neurones artificiel ayant 17 variables d'entrées

On remarque que l'apprentissage a arrêté après l'itération numéro 735, donc à l'itération numéro 735 l'erreur MSE était inférieure à 0,05.

4.5 Conclusion

En effectuant une analyse de corrélation sur les attributs d'EEG_SEG3 nous avons pu réduire le nombre des attributs de BDD_SEG3 de 20 à 17. Nous avons obtenu une meilleure performance comme l'indique tableau 23.

	Apprentissage			Test		
	P	D	N	P	D	N
Avant corrélation	100	88	100	100	81	87
Après corrélation	100	97	100	100	90	91

Tableau 23: Comparaison des résultats avant et après la corrélation

Les attributs de BDD_COR sont les suivants :

- (1) Temps cumulé d'aplatissement : TOT_IBI
- (2) Pourcentage Temps cumulé d'aplatissement : P_IBI
- (3) Plus long aplatissement : MAX_IBI
- (4) Pourcentage du plus long aplatissement : P_MAX_IBI
- (5) Temps moyen d'aplatissement : MEAN_IBI
- (6) Nombre de période d'activité faible : N_B_ faible
- (7) Temps cumulé d'activité faible : TOT_B_ faible
- (8) Pourcentage Temps cumulé d'activité faible: P_B_ faible
- (9) Plus longue activité faible: MAX_B_ faible
- (10) Temps moyen d'activité faible: MEAN_B_ faible
- (11) Nombre de période d'activité forte : N_B_ fort
- (12) Temps cumulé d'activité forte: TOT_B_ fort
- (13) Pourcentage Temps cumulé d'activité forte: P_B_ fort
- (14) Pourcentage de la plus longue activité forte : P_MAX_B_ fort
- (15) Temps moyen d'activité forte : MEAN_B_ fort
- (16) Jour de l'enregistrement EEG: OLD
- (17) Age conceptuel en semaine: AG_EEG

Enfin, notre travail nous a permis de construire un système performant basé sur une série de ces 17 variables qui sont des mesures sur les durées des intervalles d'aplatissement, ainsi que pour les intervalles d'amplitude faible et forte. Ceci va dans le sens de la conjecture des médecins [29, 30, 34, 35] et a permis d'optimiser notre système avec un rappel de 100% pour la classe pathologique, 90% pour la classe douteuse et 91% pour la classe normale. La précision a été de 93,1% dans la classe pathologique, 95,9% dans la classe douteuse et 90,7% dans la classe normale, c'est-à-dire une exactitude 93,2%. Ce système possède une bonne sensibilité pour la prévision de l'état neurologique du nouveau-né prématuré et peut servir comme outil d'aide à la décision au cours du traitement clinique.

5 Conclusion et perspective

Le signal d'électroencéphalogramme (EEG) est l'un des critères le plus souvent utilisés pour prédire un développement neurologique anormal d'un nouveau-né prématuré. C'est une mesure de l'activité électrique du cerveau via des électrodes (habituellement 10-20 système) placées sur le cuir chevelu. Elles sont réparties symétriquement sur les deux hémisphères par rapport aux régions frontales, occipitales et temporales.

Les signaux EEG contiennent des caractéristiques déterminantes qui peuvent être utilisées dans l'analyse de l'activité cérébrale. Techniquement, une caractéristique représente une propriété distinctive, une mesure reconnaissable et un composant fonctionnel obtenu à partir d'une partie d'un signal. De nombreuses caractéristiques peuvent être extraites des signaux EEG, comme la fréquence, la transformation de Fourier, l'amplitude du signal, etc...

L'objectif essentiel de notre travail est de trouver des caractéristiques du signal EEG utiles à la prévision du devenir du nouveau-né prématuré, et rapides d'extraction, pour aider les médecins à prévenir son état neurologique anormal dès sa naissance. Nous disposons pour ce travail d'une base de données concernant 397 nouveau-nés prématurés, qui comprend des informations médicales avec un enregistrement EEG à la naissance et un diagnostic deux ans après la naissance (normal, pathologique ou douteux). Cet ensemble de données est formé de 273 cas normaux, 44 pathologiques et 80 douteux : par suite il est déséquilibré puisque le nombre des cas « normaux » est beaucoup plus grand que les cas « pathologiques » et « douteux ». Nous avons ré-échantillonné les cas de la classe douteuse et de la classe pathologique pour obtenir 258 cas douteux et 209 pathologiques. L'ensemble de données est ainsi formé de 740 instances.

Physiologiquement, un signal EEG est formé d'intervalles de bouffés d'amplitude élevée interrompue par des suppressions ou des intervalles inter-bouffés (IBI). EEGDiag est une application dédiée à l'analyse du signal EEG. Cette application contient des algorithmes qui segmentent l'enregistrement EEG en phases d'activité et de suppressions, et calculent sur chaque phase les 6 mesures suivantes:

- 1- Nombre de phases
- 2- Somme de tous les intervalles de la même phase

- 3- Pourcentage de la somme de la phase parmi l'enregistrement complet
- 4- Durée de la plus longue phase
- 5- Pourcentage de la plus longue phase dans l'enregistrement complet
- 6- Durée moyenne de la phase parmi l'enregistrement complet.

L'application EEGDiag permet de calculer les valeurs de 12 variables pour chaque EEG, qui sont 6 mesures pour chaque phase de l'enregistrement. Le calcul de ces 12 mesures extraites des EEG de 740 bébés, avec pour variables additionnelles l'âge gestationnel, le jour de l'enregistrement et le diagnostic 2 ans après la naissance, nous permet de construire une base de données de 740 lignes et 15 colonnes. Cette base de données est la base d'apprentissage que nous avons appelée BDD_IBI, formée de 14 attributs d'entrée et un attribut de sortie qui est 0, 1 ou 2. "0" correspond à la classe normale, "1" correspond à la classe douteuse et "2" correspond à la classe pathologique. Chaque ligne présente une instance dans la base.

Dans l'apprentissage utilisant des modèles de classification automatique, l'ensemble de données est divisé en un ensemble d'apprentissage et un autre ensemble de test pour évaluer le rappel de la fonction de classification trouvée en comparant ses résultats aux données réelles. Habituellement, 40% au plus de l'ensemble de données doivent être utilisés pour le test. Dans notre cas, le nombre d'exemples étant limité, nous avons utilisé 80% de la base pour l'apprentissage et 20% pour le test.

Nous avons appliqué des modèles de classification automatique issues de l'analyse des données et de l'intelligence artificielle (régression linéaire multiple, analyse discriminante linéaire, machine à vecteur support, réseau de neurone artificiel et arbre de décision) sur BDD_IBI pour trouver un système de classification performant permettant de proposer un pronostic de l'état pathologique du nouveau-né prématuré dès sa naissance. La classification est satisfaisante pour les classes pathologiques (85,5%) et douteuses (90,3%), mais a besoin d'améliorations pour la classe normale (58,2%) : ceci signifie que nous avons besoin de caractéristiques plus spécifiques dans le signal pour obtenir de meilleurs résultats.

En fait, les attributs dans BDD-IBI sont basés sur la segmentation du signal EEG en 2 types d'intervalle: les intervalles bouffés et les intervalles inter-bouffés avec un seuil de $20\mu\text{v}$. Cela signifie que tous les signaux ayant une amplitude supérieure à

20 μ v ont été regroupés dans les mêmes intervalles et ont des effets similaires dans la classification. Cela a causé une perturbation dans l'apprentissage qui a conduit à une mauvaise classification. En effet, un certain nombre d'enregistrements ayant des intervalles de faible amplitude ont été classés normaux alors qu'ils étaient classés pathologiques ou douteux par les médecins. Les discussions avec les neuro-pédiatres ont indiqué qu'une faible amplitude dans le signal EEG est un marqueur qui indique une réduction de l'activité cérébrale similaire à un IBI alors qu'une amplitude élevée est un marqueur qui indique une augmentation dans l'activité du cerveau. Par suite les aplatissements et les bouffés de faible amplitude sont des bons marqueurs pour la prévision des anomalies dans le développement neurologique du bébé. Par contre les bouffés d'amplitude forte indiquent un développement neurologique normal. Selon cette théorie, nous avons créé une nouvelle méthodologie qui permet de segmenter l'amplitude des intervalles de signaux EEG en 3 segments: faible, moyenne et forte.

L'application EEGDiag est gérée de manière dynamique en fonction d'un mécanisme de plug-in qui permet de l'enrichir en lui intégrant de nouvelles fonctions. Nous avons développé un nouvel analyseur dans EEGDiag appelé SegEEG qui implémente la nouvelle méthodologie de segmentation sur les intervalles bouffés du signal EEG et les subdivise en 3 phases faible, moyenne et forte pour obtenir avec les intervalles inter-bouffés 4 phases. Puis l'analyseur calcule pour chaque phase les mêmes 6 mesures qui ont été calculées dans les intervalles bouffés et inter-bouffés.

L'application de SegEEG sur un enregistrement EEG permet d'obtenir les valeurs de 24 variables. Donc, en l'appliquant sur les EEG des 740 bébés et en ajoutant leur âge gestationnel, leur jour de l'enregistrement, et leur diagnostic 2 ans après la naissance, on obtient une base de données formée de 740 instances et 27 attributs. Cette base de données est la base d'apprentissage que nous avons appelé BDD_SEG, formée de 26 attributs d'entrée et un attribut de sortie qui est 0, 1 ou 2.

Plusieurs modèles de classifications automatiques sont testés sur cette base de données afin de résoudre le problème rencontré dans le système de classification précédent. Le rappel est de 93% dans la classe pathologiques, 92% dans la classe douteuse et 76% dans la classe normale. Ce modèle donne donc une performance satisfaisante pour la classe pathologique et douteuse mais une performance médiocre pour la classe normale. Nous avons calculé l'ordre d'importance des attributs de

chaque intervalle en utilisant l'arbre de décision pour trouver que les attributs des intervalles des bouffés d'amplitude moyenne sont les moins importants dans la décision. Nous avons éliminé ces attributs pour obtenir une nouvelle version de BDD_SEG ayant 20 variables en entrée. Dans les résultats de l'apprentissage sur cette base de données, nous avons obtenu dans le test un rappel 87% pour la classe normale, 81% pour la classe douteuse et 100% pour la classe pathologique.

Pour réduire le nombre des attributs en éliminant ceux qui sont redondants, nous avons calculé la matrice de corrélation utilisant la théorie des moments de Pearson sur les 20 attributs de BDD_SEG. Enfin, nous avons déterminé 17 variables décisives qui sont des mesures sur les durées des intervalles d'aplatissement, ainsi que pour les intervalles d'amplitude faible et forte. Ce qui a vérifié informatiquement la théorie des médecins qui indique que la durée des intervalles d'aplatissement et d'amplitude faible a une relation avec un développement anormale de l'enfant ainsi que la durée des intervalles d'amplitude forte a une relation avec un développement normal. Nous avons développé des algorithmes qui calculent les valeurs prises par ces variables dans le signal EEG et une méthode de classification efficace avec un rappel de 100% pour la classe pathologique, 90% pour la classe douteuse et 91% pour la classe normale. Ce système possède une bonne sensibilité à la prévision de l'état neurologique du nouveau-né prématuré et peut servir comme outil d'aide à la décision dans le traitement clinique.

Le rappel de la classe pathologique était parfait dans tous les tests que nous avons faits, ce qui indique que notre système est capable de détecter 100% des anomalies du prématuré dès la naissance. D'autre part, notre système a donné d'autres résultats pour 10% des cas qui étaient classés « douteux » et « normal » par les médecins. En réalité, ces cas étaient classés par le spécialiste deux ans après la naissance, mais il est possible qu'un diagnostic puisse être modifié plus tard, avec apparition de problèmes à des âges ultérieurs. La classification produite par notre système pour ces 10% pourrait être une prévision de leur futur au-delà des deux ans.

De manière à affiner les résultats déjà obtenus, nous proposons les actions suivantes :

1. Organiser un suivi spécifique pour les bébés ayant une classification par notre système qui diffère de celle des spécialistes, pour comparer leur développement

avec le résultat prévu, et pour vérifier si leur classification peut être une prévision de leur état au-delà des deux ans ou non.

2. Utiliser le diagnostic des bébés classés pathologiques par les médecins pour former de nouvelles classes dans la base de données correspondante à l'état pathologique du bébé et refaire l'apprentissage. Dans ce cas on peut pronostiquer un certain type de maladie pour le prématuré dès sa naissance et pas seulement s'il est normal ou pathologique, ce qui facilite l'intervention précoce et l'aide à la décision dans le traitement clinique.
3. D'autre part, nous avons indiqué dans la revue de la littérature qu'il existe un autre moyen de prévision de l'état pathologique et neurologique du bébé qui est l'imagerie à résonance magnétique (IRM). Ce moyen qui n'est pas moins important que l'EEG admet la dimension de la substance blanche dans l'imagerie comme marqueur. Plusieurs études ont été faites sur l'EEG et sur l'IRM chacun à part, mais les études qui utilisent ensemble les deux méthodes restent rares. Nous proposons comme perspectives à notre travail de faire des études qui intègrent ces deux méthodes pour donner des résultats plus efficaces.

Reference

- 1- Vladimir Matić, Perumpillichira J. Cherian, Katrien Jansen, Ninah Koolen, Gunnar Nauelaers, Renate M. Swarte, Paul Govaert, Gerhard H. Visser, Sabine Van Huffel and Maarten De Vos, “*Automated EEG inter-burst interval detection in neonates with mild to moderate postasphyxial encephalopathy*”. 34th Annual International Conference of the IEEE EMBS San Diego, California USA, 28 August - 1 September, 2012.
- 2- Anna Kaminska, Marie-Laure Moutard, Perrine Plouin, and Christine Soufflet, “*L’EEG en pédiatrie*“. Collection : Neurologie et épilepsie - Hors collection Editeur : John Libbey Eurotext, pages number : 185, ISBN 10 : 2742005099, ISBN 13 : 9782742005093, 2005.
- 3- Hannah Blencowe, Simon Cousens, Mikkel Zahle Oestergaard, Doris Chou, A.B. Moller, Rajesh Narwal, Alma J Adler, C. Vera Garcia, Sarah Rohde, Lale Say, and Joy E Lawn, “*National, regional, and worldwide estimates of preterm birth rates in the year 2010 with time trends since 1990 for selected countries: a systematic analysis and implications*”. Lancet. 2012; 379(9832):2162–72, Obstetric Anesthesia Digest: September 2013 - Volume 33 - Issue 3 - p 142, doi: 10.1097/01.aoa.0000432360.25014.c3, 2013.
- 4- Li Liu, Hope L Johnson, Simon Cousens, Jamie Perin, Susana Scott, Joy E Lawn, Prof Igor Rudan, Harry Campbell, Richard Cibulskis, Mengying Li, Colin Mathers, and Robert E Black, “*Global, regional, and national causes of child mortality: an updated systematic analysis for 2010 with time trends since 2000*”. The Lancet, Vol. 379, No. 9832, 09.06.2012, p. 2151-2161, 11 May 2012.
- 5- William M. Callaghan, Marian F. MacDorman, Sonja A. Rasmussen, Cheng Qin, and Eve M. Lackritz, “*The contribution of preterm birth to infant mortality rates in the United States*”. American Academy of Pediatrics. 118(4):1566–1573, doi: 10.1542/peds.2006-0860, Print ISSN: 0031-4005, Online ISSN: 1098-4275, 2006.
- 6- Neil Marlow, Dieter Wolke, Melanie A. Bracewell, and Muthanna Samara, “*Neurologic and developmental disability at six years of age after extremely preterm birth*”. The New England Journal of Medicine (Engl J Med); 352:9-19; 6 January 2005, DOI: 10.1056/NEJMoa041367, 2005.

- 7- Hayley Willacy, Anjum Gandhi, and Adrian Bonsall, ***“Premature Babies and their Problems”***. Patient Web Site, <https://patient.info/>, 2014.
- 8- Janet M Rennie , A Sehgal, A De, Giles Simon Kendall , and Tim J Cole, ***“Range of UK practice regarding thresholds for phototherapy and exchange transfusion in neonatal hyperbilirubinaemia”***. Archives of Disease in Childhood - Fetal and Neonatal Edition 94(5):F323-7 · December 2008.
- 9- Tamanna Moore, Enid M. Hennessy, Jonathan Myles, Samantha J. Johnson, Elizabeth S. Draper, Kate L. Costeloe, and Neil Marlow, ***“Neurological and developmental outcome in extremely preterm children born in England in 1995 and 2006: the EPICure studies”***. British Medical Journal, BMJ, 2012 Dec 4345:e7961. doi: 10.1136/bmj.e7961, 2012.
- 10- Maureen Hack, and Deanne Wilson Costello, ***“Decrease in frequency of cerebral palsy in preterm infants”***. Lancet. 2007 Jan 6; 369(9555):7-8. 2007.
- 11- Matthew Allin, Maeve Rooney, Marion Cuddy, John Wyatt, Muriel Walshe, Larry Rifkin, and Robin Murray, ***“Personality in young adults who are born preterm”***. American Academy of Pediatrics, 2006 Feb;117(2):309-16.2006.
- 12- Lex W. Doyle, Geoffrey Ford, and Noni Davis, ***“Health and hospitalisations after discharge in extremely low birth weight infants”***. Seminars in Neonatology 8(2):137-45 · May 2003, DOI: 10.1016/S1084-2756(02)00221-X, 2003.
- 13- Jennifer S Landry, Tiffany Chan, Larry Lands, and Dick Menzies, ***“Long-term impact of bronchopulmonary dysplasia on pulmonary function”***. Canadian respiratory journal: journal of the Canadian Thoracic Society 18(5):265-70 · September 2011.
- 14- Béatrice Larroque, Pierre-Yves Ancel, Stéphane Marret, Laetitia Marchand, Monique André, Catherine Arnaud, Véronique Pierrat, Jean-Christophe Rozé, Jean Messer, Gérard Thiriez, Antoine Burguet, Jean-Charles Picaud, Gérard Bréart, and Monique Kaminski, ***“Neurodevelopmental disabilities and special care of 5-year-old children born before 33 weeks of gestation (the EPIPAGE study): a longitudinal cohort study”***. Lancet, volume 371, Issue 9615, 8–14 March 2008, Pages 813–820
- 15- Harvey Sarnat, and Margaret Sarnat, ***“Neonatal encephalopathy following fetal distress. A clinical and electroencephalographic study”***. JAMA Neurology 33(10):696-705 · November 1976.

- 16- Gatien Hoceped, ***“Détection précoce de crises d’épilepsie à l’aide d’une modélisation du comportement oscillatoire neuronal”***. Thèse de doctorat, Université Libre de Bruxelles, 2012.
- 17- Lena Hellström-Westas, Linda S. de Vries, and Ingmar Rosen, ***“An Atlas of Amplitude-Integrated EEGs in the Newborn, Second Edition”***. CRC Press, August 31, 2008, Reference - 180 Pages - 126 B/W Illustrations ISBN 978184184649, Series: Encyclopedia of Visual Medicine Series, 2008.
- 18- Mohamed El-Dib, Taeun Chang, Tammy Tsuchida, and Robert Clancy, ***“Amplitude-integrated electroencephalography in neonates”***. *Pediatric Neurology*. 2009, Volume 41, Issue 5, November 2009, Pages 315–326, 2009.
- 19- Elisabeth Norman, Sverre Wikström, Ingmar Rosén, Vineta Fellman, and Lena Hellström-Westas, ***“Premedication for intubation with morphine causes prolonged depression of electrocortical background activity in preterm infants”***. *Pediatric Research* (2013), **73**, 87–94, doi:10.1038/pr.2012.153. 2013.
- 20- de Vries NK, TerHorst HJ, Bos AF. ***“The added value of simultaneous EEG and amplitude-integrated EEG recordings in three newborn infants”***. *Neonatology* 2007;91:212-6
- 21- Julide Sisman, Deborah E Campbell, and Luc P Brion, ***“Amplitude-integrated EEG in preterm infants: maturation of background pattern and amplitude voltage with postmenstrual age and gestational age”***. *Journal of Perinatology* 25(6):391-6 · June 2005.
- 22- Stéphanie Devuyst, ***“Classification automatique en stades du sommeil : extraction de caractéristiques et comparaison des principaux classificateurs”***. Rapport. Poly Tech Mons. 70 pages, Université de Mons, 2007.
- 23- Michel André, M-D Lamblin, A M d'Allest, and Perrine Plouin, ***“Electroencephalography in premature and full-term infants. Developmental features and glossary”***. *Neurophysiologie Clinique/Clinical Neurophysiology* 40(2):59-124 · May 2010.
- 24- Angela H Bell, B G McClure, Paul McCullagh, and Roy McClelland, ***“Variation in power spectral analysis of the EEG with gestational age”***. *Journal of Clinical Neurophysiology* 8(3):312-9 · August 1991.
- 25- Kim, H.S., Eykholt, R., Salas, J.D. ***“Nonlinear dynamics, delay times, and embedding windows”***. *Physica D* 127, 48–60 1999.

- 26- Marie-Françoise Vecchierini, Michel André, and A M d'Allest, "***Normal EEG of premature infants born between 24 and 30 weeks gestational age: terminology, definitions and maturation aspects***". *Neurophysiologie Clinique/Clinical Neurophysiology* 37(5):311-23 · October 2007.
- 27- Eisermann M, Kaminska A, Berdougou B, Brunet ML. Melatonin, "***Experience in its use for recording sleep EEG in children and review of the literature***". *Neuropediatrics*; 41(4):163—6. 2010
- 28- Matti Tolonen, J. Matias Palva, Sofi Andersson, and Sampsa Vanhatalo, "***Development of the spontaneous activity transients and ongoing cortical activity in human preterm babies***". *Neuroscience* 145(3):997-1006 · April 2007.
- 29- Jin S. Hahn, Hannelore Monyer, and Barry R. Tharp, "***Interburst interval measurements in the EEGs of premature infants with normal neurological outcome***". *Electroencephalography and Clinical Neurophysiology* 73(5):410-8 · December 1989.
- 30- Suresh Victor, Richard Appleton, and Margaret Beirne, "***Spectral analysis of electroencephalography in premature newborn infants: normal ranges***". *Pediatric Research* 03/2005; 57(3):336-41. · DOI: 10.1203/01. PDR.0000153868.77623.43, 2005.
- 31- Yamatani M, Konishi T, Murakami M, Okuda T, "***Hyperventilation activation on EEG recording in childhood***". *Epilepsia* 35:1199—203, 1994
- 32- Patrick Fuller, Joshua Gooley, and Clifford B Saper, "***Neurobiology of the sleep-wake cycle: sleep architecture, circadian regulation, and regulatory feedback***". *Journal of Biological Rhythms* 01/2007; 21(6):482-93. · DOI: 10.1177/0748730406294627, 2007.
- 33- Kazuyoshi Watanabe, Fumio Hayakawa, and Akihisa Okumura, "***Neonatal EEG: a powerful tool in the assessment of brain damage in preterm infants***". *Brain and Development* 10/1999; 21(6-21):361-372. · DOI: 10.1016/S0387-7604(99)00034-0, 1999.
- 34- Watanabe K, Hayakawa F, Okumura, Neonatal EEG: "***A powerful tool in the assessment of brain damage in preterm infants***", *Brain Dev* 21:361- 372, 1999
- 35- Hiroyuki Kidokoro, Akihisa Okumura, Fumio Hayakawa, Toru Kato, and Seiji Kojima, "***Chronologic changes in neonatal EEG findings in periventricular leukomalacia***". *Pediatrics* 09/2009; 124(3):e468-75. · DOI:10.1542/peds.2008-2967, 2009.

- 36- K Maruyama, Akihisa Okumura, F Hayakawa, T Kato, K Watanabe, and Seiji Kojima, ***“Prognostic value of EEG depression in preterm infants for later development of cerebral palsy”***. *Neuropediatrics* 07/2002; 33(3):133-7. · DOI: 10.1055/s-2002-33676, 2002.
- 37- Stéphane Marret, Dominique Parain, J F Ménard, Thierry Blanc, and Dominique Samson-Dollfus, ***“Prognostic value of neonatal electroencephalography in premature newborns less than 33 weeks of gestational age”***. *Electroencephalography and Clinical Neurophysiology* 03/1997; 102(3):178-85. · DOI: 10.1016/S0013-4694(96)95655-6, 1997.
- 38- E. Biagioni, MF. Frisone, S. Laroche, BA. Kapetanakis, D. Ricci, M. Adeyi-Obe M et al., ***“Maturation of cerebral electrical activity and development of cortical folding in young very preterm infants”***, *Clin Neurophysiol*, J. PubMed, vol 118(1), pp.53-9, Jan. 2007.
- 39- Greisen G. ***“Tape-recorded EEG and the cerebral function monitor: amplitude-integrated, time-compressed EEG”***. *J Perinat Med*; 22: 541–546, 1994.
- 40- Hellström-Westas L, Klette H, Thorngren-Jerneck K & Rosen I. ***“Early prediction of outcome with aEEG in preterm infants with large intraventricular hemorrhages”***. *Neuropediatrics* 32: 319–324, 2001
- 41- Davide Vito Moretti, Fabio Babiloni, Filippo Carducci, Febo Cincotti, and Claudio Babiloni, ***“Computerized processing of EEG–EOG–EMG artifacts for multicentric studies in EEG oscillations and event-related potentials”***, *International Journal of Psychophysiology*, Vol.47, Is.3, 199–216, 2003.
- 42- Piotr J Durka, Hubert Klekowicz, Katarzyna Blinowska, Waldemar Szelenberger, and Szymon Niemcewicz, ***“A simple system for detection of EEG artifacts in polysomnographic recordings”***. *IEEE Transactions on Biomedical engineering*, Vol. 50, No. 4, 526-528, 2003.
- 43- Hae-Jeong Park, Do-Un Jeong, and Kwang Suk Park, ***“Automated detection and elimination of periodic ECG artifacts in EEG using the energy interval histogram method”***. *IEEE Transactions on Biomedical engineering*, Vol. 49, No.12, 1526-1533, 2002.
- 44- Rodney J Croft, and Robert Barry, ***“Removal of ocular artifact from the EEG: a review”***. *Neurophysiologie Clinique/Clinical Neurophysiology* 03/2000; 30(1):5-19. · DOI: 10.1016/S0987-7053(00)00055-1, 2000.

- 45- Boualem Boashash, Patrick Celka, and Paul Colditz, ***“Preprocessing and time-frequency analysis of newborn EEG seizures”***, IEEE Engineering in Medicine and Biology Magazine 09/2001; 20(5). · DOI:10.1109/51.956817, 2001.
- 46- R. Broughton, J. Fleming, and J. Fleetham, ***“Home assessment of sleep disorders by portable monitoring,”*** J. Clin. Neurophys., vol. 13, no. 4, pp. 272–284, 1996.
- 47- Moretti D.V., Babiloni F., Carducci F., Cincotti F., Remondini E., Rossini P.M., Salinari S., Babiloni C., ***“Computerized processing of EEG–EOG–EMG artifacts for multicentric studies in EEG oscillations and event-related potentials”***, International Journal of Psychophysiology, Vol.47, Is.3, pp 199–216, 2003.
- 48- Durka P.J., Klekowicz H., Blinowska K.J., Szelenberger W., Niemcewicz Sz., ***“A simple system for detection of EEG artifacts in polysomnographic recordings”***, IEEE Transactions on Biomedical engineering, Vol. 50, No. 4, 526-528, 2003.
- 49- Kristin Keunen, Karina Kersbergen, Floris Groenendaal, Ivana Isgum, and Manon J N L Benders, ***“Brain tissue volumes in preterm infants: prematurity, perinatal risk factors and neurodevelopmental outcome: a systematic review”***. The journal of maternal-fetal & neonatal medicine: the official journal of the European Association of Perinatal Medicine, the Federation of Asia and Oceania Perinatal Societies, the International Society of Perinatal Obstetricians 02/2012; 25 Suppl 1(S1):89-100. · DOI:10.3109/14767058.2012.664343. 2012.
- 50- Jorrit F de Kieviet, Lydia Zoetebier, Ruurd Van Elburg, R Jeroen Vermeulen, and Jaap Oosterlaan, ***“Brain development of very preterm and very low-birthweight children in childhood and adolescence: a meta-analysis”***. Developmental Medicine & Child Neurology 01/2012; 54(4):313-23. · DOI:10.1111/j.1469-8749.2011.04216.x, 2012.
- 51- Aarnoudse-Moens CS, Weisglas-Kuperus N, van Goudoever JB, Oosterlaan J. ***“Meta-analysis of neurobehavioral outcomes in very preterm and/or very low birth weight children”***. Pediatrics.124:717–28, 2009.
- 52- Lianne Woodward, Peter J Anderson, Nicola C Austin, Kelly Howard, and Terrie E Inder, ***“Neonatal MRI to Predict Neurodevelopmental Outcomes in Preterm Infants”***. New England Journal of Medicine 355(7):685-94 · September 2006.
- 53- R Edwin Spitzmiller, Tonya Phillips, Jareen Meinzen-Derr, and Steven B Hoath, ***“Amplitude-integrated EEG is useful in predicting neurodevelopmental outcome in full-term infants with hypoxic-ischemic encephalopathy: a meta-analysis”***. Journal of Child Neurology 22(9):1069-78 · October 2007.

- 54- Pierre Chauvet, and Sylvie Nguyen, ***“EEGDiag, une application d’analyse de l’EEG pour la plateforme de télésanté BBEEG 4ièmes”***. Journées Démonstrateurs, France-Angers, 2013.
- 55- Cesaro Lombroso, ***“Neonatal polygraphy in full-term and premature infants: a review of normal and abnormal findings”***. Journal of Clinical Neurophysiology: April 1985 - Volume 2 - Issue 2 - ppg 105-156, 1985.
- 56- Monika Olischar, Katrin Klebermab-Schrehof, Stefan Kuhle, Margot Hulek, and Manfred Weninger, ***“Reference values for amplitude-integrated electroencephalographic activity in preterm infants younger than 30 weeks’ gestational age”***. Pediatrics 113(1 Pt 1):e61-6 · January 2004.
- 57- Mohamed El-Dib, An N Massaro, Dorothy I Bulas, and Hany Z Aly, ***“Neuroimaging and neurodevelopmental outcome of premature infants”***. American Journal of Perinatology 11/2010; 27(10):803-18. · DOI: 10.1055/s-0030-1254550, 2010.
- 58- Lena Hellström-Westas, H Klette, Kristina Thorngren-Jerneck, and I Rosén, ***“Early prediction of outcome with aEEG in preterm infants with large intraventricular hemorrhages”***. Neuropediatrics 32(6):319-24 · January 2002.
- 59- Hintz SR, O’Shea M ***“Neuroimaging and neurodevelopmental outcomes in preterm infants”***. Semin Perinatol **32**:11–19. 2008.
- 60- Niemarkt HJ, Halbertsma FJ, Andriessen P, Bambang Oetomo S. ***“Amplitude-integrated electroencephalographic changes in a newborn induced by overdose of morphine and corrected with naloxone”***. Acta Paediatr. 97(1):132–4. January 2008.
- 61- Sisman J, Campbell DE, Brion LP. ***“Amplitude-integrated EEG in preterm infants: maturation of background pattern and amplitude voltage with postmenstrual age and gestational age”***. J Perinatol. 25(6):391–6. January 2005.
- 62- Vladimir F Burdjalov, Stephen Baumgart, and Alan R Spitzer, ***“Cerebral function monitoring: a new scoring system for the evaluation of brain maturation in neonates”***. Pediatrics 112(4):855-61 · November 2003.
- 63- Caroline C Menache, Blaise F D Bourgeois, and Joseph J Volpe, ***“Prognostic value of neonatal discontinuous EEG”***. Pediatric Neurology 27(2):93-101 · September 2002.
- 64- Victor S, Appleton RE, Beirne M, Marson AG, Weindling AM. ***“Spectral analysis of electroencephalography in premature newborn infants: normal ranges”***. Pediatrics 57(3):336–41. 2005.

- 65- R. Rakotomalala, "**TANAGRA : Une Plate-Forme d'Expérimentation pour la Fouille de Données**". Revue MODULAD, 32, 70-85, 2005.
- 66- Douglas Montgomery, Elizabeth Peck, and Geoffrey Vinig, "**Introduction to linear Regression Analysis**". Book, ISBN: 978-0-470-54281-1, 672 pages, April 2012.
- 67- Xin Yan, and Xiao Gang Su, "**Linear Regression Analysis: Theory and Computing**". Book, ISBN: 9812834109 9789812834102 World Scientific Publishing Co., Inc. River Edge, NJ, USA 2009.
- 68- Ryan Tibshirani, "**Data Mining: Spring 2013**". Carnegie Mellon University Pittsburgh, PA 15213. 2013.
- 69- Asa Ben-Hur, Jason Weston, "**A user's guide to support vector machines**". Data mining techniques for the life sciences, Pages: 223-239, Publisher: Humana Press, 2010.
- 70- Payam Emami Khoonsari and AhmadReza Motie, "**A Comparison of Efficiency and Robustness of ID3 and C4.5 Algorithms Using Dynamic Test and Training Data Sets**" International Journal of Machine Learning and Computing, Vol. 2, No. 5, October 2012.
- 71- Caruana R, Niculescu-Mizil A. "**An empirical comparison of supervised learning algorithms**". Proceedings of the Twenty-Third International Conference; New York: ACM; pp. 161–168. 2003.
- 72- Gareth James, Daniela Witten, Trevor Hastie and Robert Tibshirani, "**An Introduction to Statistical Learning**". New York: Springer. p. 315. ISBN 978-1-4614-7137-0, 2015.
- 73- Letham, Ben; Rudin, Cynthia; McCormick, Tyler; Madigan, David "**Interpretable Classifiers Using Rules And Bayesian Analysis: Building A Better Stroke Prediction Model**". Annals of Applied Statistics. 9: pp1350–1371. 2015.
- 74- Sreerama K. Murthy, "**Automatic construction of decision trees from data: A multidisciplinary survey**". Data Mining and Knowledge Discovery 03/2000; 2(4). · DOI: 10.1023/A:1009744630224, 2000.
- 75- O. C. Akinyokun, "**Neuro – fuzzy Expert system for Evaluation of Human Resources Performance**". First Bank of Nigeria PLC Endowment Fund Lecture, The Federal University of Technology Akure, Nigeria, 2002
- 76- Dan Cireşan, Ueli Meier, Jonathan Masci, and Jürgen Schmidhuber, "**Multi-Column Deep Neural Network for Traffic Sign Classification**". Neural networks: the official

- journal of the International Neural Network Society 02/2012; 32:333-8. · DOI:10.1016/j.neunet.2012.02.023, 2012.
- 77- Tatsuo Takeuchi, and Kazuyoshi Watanabe, "***The EEG evolution and neurological prognosis of perinatal hypoxia neonates***", Brain and Development 02/1989; 11(2):115-20. · DOI: 10.1016/S0387-7604(89)80079-8, 1989.
- 78- Biagioni E, Boldrini A, Giganti F, Guzzetta A, Salzarulo P, Cioni G. "***Distribution of sleep and wakefulness EEG patterns in 24-h recordings of preterm and full-term newborns***". Early Hum Dev. 81:333–9. 2005.
- 79- Vaishali Ganganwar, "***An overview of classification algorithms for imbalanced datasets***", International Journal of Emerging Technology and Advanced Engineering Website: www.ijetae.com (ISSN 2250-2459, Volume 2, Issue 4), 2012
- 80- Mohamed El-Dib, Taeun Chang, Tammy N. Tsuchida, and Robert R. Clancy, "***Amplitude-integrated electroencephalography in neonates***". Pediatric Neurology, November 2009, Volume 41, Issue 5, Pages 315–326 2009.
- 81- Ron Kohavi, and Foster Provost, "***Glossary of terms***". Special Issue on Applications of Machine Learning and the Knowledge Discovery Process, Machine Learning, **30**, 271–274, 1998
- 82- Miles N. Wernick, Yongyi Yang, Jovan G. Brankov, Grigori Yourganov, and Stephen C. Strother, "***Machine Learning in Medical Imaging***". IEEE Signal Processing Magazine, vol. 27, no. 4, p. 25–38, July 2010.
- 83- M. Tranmer, and M. Elliot, "***Multiple Linear Regression***". The Cathie Marsh Centre for Census and Survey Research (CCSR), 2008.
- 84- S. Balakrishnama, and Aravind Ganapathiraju, "***Linear Discriminant Analysis - A Brief Tutorial***". Institute for Signal and Information Processing, Department of Electrical and Computer Engineering, Mississippi State University, 1998.
- 85- Jiansheng Wu, and Enhong Chen, "***A Novel Nonparametric Regression Ensemble for Rainfall Forecasting Using Particle Swarm Optimization Technique Coupled with Artificial Neural Network***". Advances in Neural Networks – ISNN 2009 · 05/2009: pages 49-58; · DOI:10.1007/978-3-642-01513-7_6, 2009.
- 86- Peter Chen PY, and Paula Popovich, "***Correlation: Parametric and Nonparametric Measures***". Thousand Oaks, CA: Sage Publications, ISBN-13: 978-0761922285, ISBN-10: 0761922288, 2002.
- 87- Jeremy M. G. Taylor, "***Kendall's and Spearman's Correlation Coefficients in the Presence of a Blocking Variable***". Biometrics. 1987;43:409-416, 1987.

- 88- David M W, "*Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation*". Journal of Machine Learning Technologies. 2 (1): 37–63, 2011.

Publications

Conférence internationale

- [C1] **Y. Hajjar**, A. Al Hajjar, B. Daya, P. Chauvet “*Determinant characteristics in EEG signal based on bursts amplitude segmentation for predicting pathological outcomes of a premature newborn*”, SENSET2017 is the first International Conference on Sensors, Networks, Smart and Emerging Technologies, 12-14 September 2017 , Beirut- Lebanon, published in IEEE eXplore Digital Library, 2017.
- [C2] **Y. Hajjar**, A. Al Hajjar, B. Daya, P. Chauvet “*Predication of premature neonates prognosis based on their electroencephalogram using Artificial Neural Network*”, SAI Intelligent Systems Conference 2015, IEEE, November 10-11, 2015 | London, United Kingdom, 2015.

Journal

- [J1] **Y. Hajjar**, A. Al Hajjar, B. Daya, P. Chauvet , “*Intelligent models to predict the prognosis of premature neonates according to their EEG signals*”, International Journal of Biomedical and Clinical Engineering (IJBCE) Volume 6, Issue 1, 2017.
- [J2] **Y. Hajjar**, A. Al Hajjar, B. Daya, P. Chauvet , “*Automatic classification and correlative data analysis of EEG signal to Predict neuro-developmental risk of premature neonates*”, *Engineering Applications of Artificial Intelligence, ELSEVIER, 2017* (submitted).

Annexe

Annexe1 : Régression linéaire multiple

```
inputs=xlsread('inputs.xlsx');
inputs=inputs';
targets=xlsread('o.xlsx');
targets=targets';
% group the input data of each class in separate matrices
M0=zeros(26,0); n0=1;
M1=zeros(26,0); n1=1;
M2=zeros(26,0); n2=1;
N0=zeros(1,0);
N1=zeros(1,0);
N2=zeros(1,0);
for i=1:741
    if( targets(i)==1) M0(1:26,n0)=inputs(1:26,i);
        N0(1,n0)=1;
        n0=n0+1;
    else
        if( targets(i)==0.5)
            M1(1:26,n1)=inputs(1:26,i);
            N1(1,n1)=0.5;
            n1=n1+1;
        else M2(1:26,n2)=inputs(1:26,i);
            N2(1,n2)=0;
            n2=n2+1;
        end
    end
end
end

[train_M0,test_M0]=dividerand(M0,0.8,0.2,0);
[train_M1,test_M1]=dividerand(M1,0.8,0.2,0);
[train_M2,test_M2]=dividerand(M2,0.8,0.2,0);
[train_N0,test_N0]=dividerand(N0,0.8,0.2,0);
[train_N1,test_N1]=dividerand(N1,0.8,0.2,0);
[train_N2,test_N2]=dividerand(N2,0.8,0.2,0);
```

```

% create training data matrices for the tree
train_inputs=[train_M0 train_M1 train_M2];
train_targets=[train_N0 train_N1 train_N2];

%create testing data matrices for the tree
test_inputs=[test_M0 test_M1 test_M2];
test_targets=[test_N0 test_N1 test_N2];

[b,bint,r,rint] = regress(train_targets',train_inputs');
train_output=train_inputs'*b;
test_output=test_inputs'*b;

M=train_output';
for i=1:593
    if(M(1,i)<0.4) M(1,i)=0;
    else if(M(1,i)<0.7) M(1,i)=0.5;
    else M(1,i)=1;
    end
end
end
train_output=M';
M_targets=zeros(3,0);
M_outputs=zeros(3,0)
for i=1:593
    if(train_targets(i)==1)M_targets(3,i)=1;
    else if(train_targets(i)==0.5)M_targets(2,i)=1;
    else M_targets(1,i)=1;
    end
end
end
if(train_output(i)==1)M_outputs(3,i)=1;
else if(train_output(i)==0.5)M_outputs(2,i)=1;
    else M_outputs(1,i)=1;
    end
end
end
end

N=test_output';

```

```

for i=1:148
    if(N(1,i)<0.4) N(1,i)=0;
    else if(N(1,i)<0.7) N(1,i)=0.5;
        else N(1,i)=1;
    end
end
end
test_output=N';
N_targets=zeros(3,0);
N_outputs=zeros(3,0)
for i=1:148
    if(test_targets(i)==1)N_targets(3,i)=1;
    else if(test_targets(i)==0.5)N_targets(2,i)=1;
        else N_targets(1,i)=1;
    end
end
if(test_output(i)==1)N_outputs(3,i)=1;
else if(test_output(i)==0.5)N_outputs(2,i)=1;
    else N_outputs(1,i)=1;
end
end
end
figure,plotconfusion(M_targets,M_outputs,'Training data',N_targets,N_outputs,'Testing
data')

```

Annexe2 : Analyse discriminante linéaire

```

% import the input and target data
% data is rearranged such that every columns is a data sample
inputs=xlsread('inputs.xlsx');
inputs=inputs';
targets=xlsread('o.xlsx');
targets=targets';

% group the input data of each class in separate matrices
% group the input data of each class in separate matrices
M0=zeros(26,0); n0=1;
M1=zeros(26,0); n1=1;

```

```

M2=zeros(26,0); n2=1;
N0=zeros(1,0);
N1=zeros(1,0);
N2=zeros(1,0);
for i=1:741
    if( targets(i)==1) M0(1:26,n0)=inputs(1:26,i);
        N0(1,n0)=1;
        n0=n0+1;
    else
        if( targets(i)==0.5)
            M1(1:26,n1)=inputs(1:26,i);
            N1(1,n1)=0.5;
            n1=n1+1;
        else M2(1:26,n2)=inputs(1:26,i);
            N2(1,n2)=0;
            n2=n2+1;
        end
    end
end
end

```

```

[train_M0,test_M0]=dividerand(M0,0.8,0.2,0);
[train_M1,test_M1]=dividerand(M1,0.8,0.2,0);
[train_M2,test_M2]=dividerand(M2,0.8,0.2,0);
[train_N0,test_N0]=dividerand(N0,0.8,0.2,0);
[train_N1,test_N1]=dividerand(N1,0.8,0.2,0);
[train_N2,test_N2]=dividerand(N2,0.8,0.2,0);

```

```

% create training data matrices for the tree
train_inputs=[train_M0 train_M1 train_M2];
train_inputs=train_inputs';
train_targets=[train_N0 train_N1 train_N2];
train_targets=train_targets';

```

```

%create testing data matrices for the tree
test_inputs=[test_M0 test_M1 test_M2];
test_inputs=test_inputs';
test_targets=[test_N0 test_N1 test_N2];

```

```

test_targets=test_targets';

obj=fitcdiscr(train_inputs,train_targets);

train_outputs=predict(obj,train_inputs);

test_outputs=predict(obj,test_inputs);

%transform train_targets et train_outputs en matrices de 3 colonne
M_targets=zeros(3,0);
M_outputs=zeros(3,0);
for i=1:593
    if(train_targets(i)==1)M_targets(3,i)=1;
    else if(train_targets(i)==0.5)M_targets(2,i)=1;
        else M_targets(1,i)=1;
    end
end
if(train_outputs(i)==1)M_outputs(3,i)=1;
else if(train_outputs(i)==0.5)M_outputs(2,i)=1;
    else M_outputs(1,i)=1;
    end
end
end

%transform test_targets et test_outputs en matrices de 3 colonne
N_targets=zeros(3,0);
N_outputs=zeros(3,0);
for i=1:148
    if(test_targets(i)==1)N_targets(3,i)=1;
    else if(test_targets(i)==0.5)N_targets(2,i)=1;
        else N_targets(1,i)=1;
    end
end
if(test_outputs(i)==1)N_outputs(3,i)=1;
else if(test_outputs(i)==0.5)N_outputs(2,i)=1;
    else N_outputs(1,i)=1;
    end
end

```

```

    end
end
figure,plotconfusion(M_targets,M_outputs,'Training data',N_targets,N_outputs,'Testing
data')

```

Annexe3 : Machines à vecteurs support

```

filename <- "d:/testresultatyasser.xls"
xlsFile <- odbcConnectExcel(filename, readOnly = FALSE)
c <- sqlFetch(xlsFile,"firstdataset")
ClassN<-subset(c,Class=="N")
dt = sort(sample(nrow(ClassN), nrow(ClassN)*.805))
trainN<-ClassN[dt,]
testN<-ClassN[-dt,]
nrow(testN)
nrow(trainN)

ClassD<-subset(c,Class=="D")
dt = sort(sample(nrow(ClassD), nrow(ClassD)*.8))
trainD<-ClassD[dt,]
testD<-ClassD[-dt,]
nrow(testD)
nrow(trainD)

ClassP<-subset(c,Class=="P")
dt = sort(sample(nrow(ClassP), nrow(ClassP)*.805))
trainP<-ClassP[dt,]
testP<-ClassP[-dt,]
nrow(testP)
nrow(trainP)
train<-rbind(trainN,trainD,trainP)
test<-rbind(testN,testD,testP)
nrow(train)
nrow(test)
attach(train)
x<-subset(train, select=-Class )
nrow(x)
y<-subset(train, select=Class )

```

```

y<-Class
svm_model <- svm(Class ~ ., data=train)
pred <- predict(svm_model,x)
length(y)
summary(svm_model)
table(pred,y)
nrow(test)
attach(test)
z<-subset(test, select=-Class )
v<-subset(test, select=Class )
v<-Class
length(pred)
pred <- predict(svm_model,z)
pred
table(pred,v)

library("e1071")
library(RODBC)
filename <- "d:/testresultatyasser.xls"
xlsFile <- odbcConnectExcel(filename, readOnly = FALSE)
c <- sqlFetch(xlsFile,"SecondDataset")
ClassN<-subset(c,Class=="N")
dt = sort(sample(nrow(ClassN), nrow(ClassN)*.805))
trainN<-ClassN[dt,]
testN<-ClassN[-dt,]
nrow(testN)
nrow(trainN)

ClassD<-subset(c,Class=="D")
dt = sort(sample(nrow(ClassD), nrow(ClassD)*.8))
trainD<-ClassD[dt,]
testD<-ClassD[-dt,]
nrow(testD)
nrow(trainD)

ClassP<-subset(c,Class=="P")
dt = sort(sample(nrow(ClassP), nrow(ClassP)*.805))

```

```

trainP<-ClassP[dt,]
testP<-ClassP[-dt,]
nrow(testP)
nrow(trainP)

train<-rbind(trainN,trainD,trainP)
test<-rbind(testN,testD,testP)
nrow(train)
nrow(test)
attach(train)
x<-subset(train, select=-Class )
nrow(x)
y<-subset(train, select=Class )
y<-Class

svm_model <- svm(Class ~ ., data=train)
pred <- predict(svm_model,x)
length(y)
summary(svm_model)
table(pred,y)
nrow(test)
attach(test)
z<-subset(test, select=-Class )
v<-subset(test, select=Class )
v<-Class
length(pred)
pred <- predict(svm_model,z)
table(pred,v)

library("e1071")
library(RODBC)
filename <- "d:/testresultatyasser.xls"
xlsFile <- odbcConnectExcel(filename, readOnly = FALSE)
c <- sqlFetch(xlsFile,"SecondDataset")
attach(c)
x<-subset(c, select=-Class )

```

```

y<-subset(c, select=Class )
y<-Class
svm_model <- svm(Class ~ ., data=c)
pred <- predict(svm_model,x)
nrow(y)
table(pred,y)
summary(svm_model)
d <- sqlFetch(xlsFile,"TestFirst2")
attach(d)
z<-subset(d, select=-Class )
v<-subset(d, select=Class )
v<-Class

```

```

pred <- predict(svm_model,z)
pred
table(pred,head(v,147))
y
odbcClose(xlsFile)
table(pred,y)
length(y)
head(x,20)
list(pred)

```

Annexe4 : Réseaux de neurones artificiels (RNA)

% faire le test seulement avec 11 parametres: %temps cumule,plus long et % de plus

long

% data is rearranged such that every columns is a data sample

```
inputs=xlsread('inputs_11_parametre.xlsx');
```

```
inputs=inputs';
```

```
targets=xlsread('o.xlsx');
```

```
targets=targets';
```

% group the input data of each class in separate matrices

% group the input data of each class in separate matrices

```
M0=zeros(11,0); n0=1;
```

```
M1=zeros(11,0); n1=1;
```

```
M2=zeros(11,0); n2=1;
```

```

N0=zeros(1,0);
N1=zeros(1,0);
N2=zeros(1,0);
for i=1:741
    if( targets(i)==1) M0(1:11,n0)=inputs(1:11,i);
        N0(1,n0)=1;
        n0=n0+1;
    else
        if( targets(i)==0.5)
            M1(1:11,n1)=inputs(1:11,i);
            N1(1,n1)=0.5;
            n1=n1+1;
        else M2(1:11,n2)=inputs(1:11,i);
            N2(1,n2)=0;
            n2=n2+1;
        end
    end
end
end

```

```

[train_M0,test_M0]=dividerand(M0,0.8,0.2,0);
[train_M1,test_M1]=dividerand(M1,0.8,0.2,0);
[train_M2,test_M2]=dividerand(M2,0.8,0.2,0);
[train_N0,test_N0]=dividerand(N0,0.8,0.2,0);
[train_N1,test_N1]=dividerand(N1,0.8,0.2,0);
[train_N2,test_N2]=dividerand(N2,0.8,0.2,0);

```

```

% create training data matrices for the tree
train_inputs=[train_M0 train_M1 train_M2];
train_inputs=train_inputs';
train_targets=[train_N0 train_N1 train_N2];
train_targets=train_targets';

```

```

%create testing data matrices for the tree
test_inputs=[test_M0 test_M1 test_M2];
test_inputs=test_inputs';
test_targets=[test_N0 test_N1 test_N2];
test_targets=test_targets';

```

```

% Create a Pattern Recognition Network
hiddenLayerSize = 10;%number of neurons
net1 = patternnet(hiddenLayerSize);

% Choose Input and Output Pre/Post-Processing Functions
% For a list of all processing functions type: help nnprocess
net1.inputs{1}.processFcns={'removeconstantrows','mapminmax'};
net1.inputs{1}.processParams{2}.ymin=-3;
net1.inputs{1}.processParams{2}.ymax=3;

% Setup Division of Data for Training, Validation, Testing
% For a list of all data division functions type: help nndivide
net1.divideFcn = 'dividetrain'; % Divide data randomly
net1.divideMode = 'sample'; % Divide up every sample

% For help on training function 'trainlm' type: help trainlm
% For a list of all training functions type: help nntrain
net1.trainFcn = 'trainlm'; % Levenberg-Marquardt

% Choose a Performance Function
% For a list of all performance functions type: help nnperformance
net1.performFcn = 'mse'; % Mean squared error

% Choose Plot Functions
% For a list of all plot functions type: help nnplot
net1.plotFcns = {'plotperform','plotroc','plotconfusion'};

% Train the Network
[net1,tr] = train(net1,train_inputs',train_targets');

% Calculate mse and AUC

```

```

% for training data
train_outputs= net1(train_inputs');
M=train_outputs;
for i=1:592
    if(M(1,i)<0.25) M(1,i)=0;
    else if(M(1,i)<0.75) M(1,i)=0.5;
    else M(1,i)=1;
    end
end
end
train_outputs=M';
[x,y,t,AUCtrain]=perfcurve(train_targets,train_outputs,1);
AUCtrain
msetrain=perform(net1,train_targets,train_outputs)

% for test data
test_outputs= net1(test_inputs');
N=test_outputs;
for i=1:148
    if(N(1,i)<0.25) test_outputs(1,i)=0;
    else if(N(1,i)<0.75) test_outputs(1,i)=0.5;
    else test_outputs(1,i)=1;
    end
end
end
test_outputs=test_outputs';
[a,b,t,AUCtest]=perfcurve(test_targets,test_outputs,1);
AUCtest
msetest=perform(net1,test_targets,test_outputs)

% Plot ROC, confusion matrix,
%transform train_targets et train_outputs en matrices de 3 colonne
M_targets=zeros(3,0);
M_outputs=zeros(3,0);
for i=1:593
    if(train_targets(i)==1)M_targets(3,i)=1;
    else if(train_targets(i)==0.5)M_targets(2,i)=1;

```

```

        else M_targets(1,i)=1;
    end
end
if(train_outputs(i)==1)M_outputs(3,i)=1;
else if(train_outputs(i)==0.5)M_outputs(2,i)=1;
    else M_outputs(1,i)=1;
    end
end
end
end

%transform test_targets et test_outputs en matrices de 3 colonne
N_targets=zeros(3,0);
N_outputs=zeros(3,0);
for i=1:148
    if(test_targets(i)==1)N_targets(3,i)=1;
    else if(test_targets(i)==0.5)N_targets(2,i)=1;
        else N_targets(1,i)=1;
        end
    end
    if(test_outputs(i)==1)N_outputs(3,i)=1;
    else if(test_outputs(i)==0.5)N_outputs(2,i)=1;
        else N_outputs(1,i)=1;
        end
    end
end
end

figure,plotconfusion(M_targets,M_outputs,'Training data',N_targets,N_outputs,'Testing
data')
figure
subplot(2,1,1),plot(x,y),title('Training ROC')
subplot(2,1,2),plot(a,b),title('Testing ROC')

```

Annexe5 : Arbre de décision

```

% import the input and target data
% data is rearranged such that every columns is a data sample
inputs=xlsread('inputs.xlsx');

```

```

inputs=inputs';
targets=xlsread('o.xlsx');
targets=targets';
max=0;h=0
% repeter l'arbre 100 fois puis donner celle qui donne le meilleur resultat
while (h<100)
% group the input data of each class in separate matrices
M0=zeros(26,0); n0=1;
M1=zeros(26,0); n1=1;
M2=zeros(26,0); n2=1;
N0=zeros(1,0);
N1=zeros(1,0);
N2=zeros(1,0);
for i=1:741
    if( targets(i)==1) M0(1:26,n0)=inputs(1:26,i);
        N0(1,n0)=1;
        n0=n0+1;
    else
        if( targets(i)==0.5)
            M1(1:26,n1)=inputs(1:26,i);
            N1(1,n1)=0.5;
            n1=n1+1;
        else M2(1:26,n2)=inputs(1:26,i);
            N2(1,n2)=0;
            n2=n2+1;
        end
    end
end
end

[train_M0,test_M0]=dividerand(M0,0.8,0.2,0);
[train_M1,test_M1]=dividerand(M1,0.8,0.2,0);
[train_M2,test_M2]=dividerand(M2,0.8,0.2,0);
[train_N0,test_N0]=dividerand(N0,0.8,0.2,0);
[train_N1,test_N1]=dividerand(N1,0.8,0.2,0);
[train_N2,test_N2]=dividerand(N2,0.8,0.2,0);

% create tarining data matrices for the tree

```

```

train_inputs=[train_M0 train_M1 train_M2];
train_inputs=train_inputs';
train_targets=[train_N0 train_N1 train_N2];
train_targets=train_targets';

%create testing data matrices for the tree
test_inputs=[test_M0 test_M1 test_M2];
test_inputs=test_inputs';
test_targets=[test_N0 test_N1 test_N2];
test_targets=test_targets';

% create the tree
tree = classregtree(train_inputs,train_targets,'names',{'N_IBI','TOT_IBI','P_IBI'
    , 'MAX_IBI'    , 'P_MAX_IBI' , 'MEAN_IBI'    , 'N_B_Faible' , 'TOT_B_Faible',
    'P_B_Faible' , 'MAX_B_Faible'    , 'P_MAX_B_Faible' , 'MEAN_B_Faible'
    , 'N_B_Moy'   , 'TOT_B_Moy', 'P_B_Moy'    , 'MAX_B_Moy'    , 'P_MAX_B_Moy'
    , 'MEAN_B_Moy'    , 'N_B_Fort'    , 'TOT_B_Fort' , 'P_B_Fort'    , 'MAX_B_Fort'
    , 'P_MAX_B_Fort'    , 'MEAN_B_Fort'    , 'age'    , 'T'});
%view(tree)
%tree = classregtree(train_inputs,train_targets,'names',{'N_IBI','TOT_IBI','P_IBI'
    , 'MAX_IBI'    , 'P_MAX_IBI' , 'MEAN_IBI'    , 'N_B_Faible' , 'TOT_B_Faible',
    'P_B_Faible' , 'MAX_B_Faible'    , 'P_MAX_B_Faible' , 'MEAN_B_Faible'
    , 'N_B_Fort'   , 'TOT_B_Fort' , 'P_B_Fort'    , 'MAX_B_Fort' , 'P_MAX_B_Fort'
    , 'MEAN_B_Fort'    , 'age'    , 'T'});
%view(tree)

%calculate AUC and plot confusion matrix

% for training data
train_outputs= tree(train_inputs);
M=train_outputs';
for i=1:592
    if(M(1,i)<0.25) M(1,i)=0;
    else if(M(1,i)<0.75) M(1,i)=0.5;
    else M(1,i)=1;
    end
end

```

```

    end
end
train_outputs=M';
[x,y,t,AUCtrain]=perfcurve(train_targets',train_outputs',1);
AUCtrain

% for test data
test_outputs= tree(test_inputs);
test_outputs=test_outputs';
N=test_outputs;
for i=1:148
    if(N(1,i)<0.25) test_outputs(1,i)=0;
    else if(N(1,i)<0.75) test_outputs(1,i)=0.5;
    else test_outputs(1,i)=1;
    end
end
end
test_outputs=test_outputs';
[a,b,t,AUCtest]=perfcurve(test_targets',test_outputs',1);
AUCtest
h=h+1
if(AUCtest>max)max=AUCtest
    tree_max=tree;
    train_targets_max=train_targets;
    train_outputs_max=train_outputs;
    test_targets_max=test_targets;
    test_outputs_max=test_outputs;
    test_inputs_max=test_inputs;
    train_inputs_max=train_inputs;
    N_max=N';
end
end
view(tree_max)

%transform train_targets et train_outputs en matrices de 3 colonne
M_targets=zeros(3,592);

```

```

M_outputs=zeros(3,592);
for i=1:592
    if(train_targets_max(i)==1)M_targets(3,i)=1;
    else if(train_targets_max(i)==0.5)M_targets(2,i)=1;
        else M_targets(1,i)=1;
    end
end
if(train_outputs_max(i)==1)M_outputs(3,i)=1;
else if(train_outputs_max(i)==0.5)M_outputs(2,i)=1;
    else M_outputs(1,i)=1;
    end
end
end

%transform test_targets et test_outputs en matrices de 3 colonne
N_targets=zeros(3,148);
N_outputs=zeros(3,148);
for i=1:148
    if(test_targets_max(i)==1)N_targets(3,i)=1;
    else if(test_targets_max(i)==0.5)N_targets(2,i)=1;
        else N_targets(1,i)=1;
    end
end
if(test_outputs_max(i)==1)N_outputs(3,i)=1;
else if(test_outputs_max(i)==0.5)N_outputs(2,i)=1;
    else N_outputs(1,i)=1;
    end
end
end

figure,plotconfusion(M_targets,M_outputs,'Training data',N_targets,N_outputs,'Testing
data')
figure
subplot(2,1,1),plot(x,y),title('Training ROC')
subplot(2,1,2),plot(a,b),title('Testing ROC')

```

Thèse de Doctorat

Yasser ALHAJJAR

Prévision du risque neuro-développemental du nouveau-né prématuré par classification automatique du signal EEG

Résumé

L'électroencéphalogramme (EEG), mesure de l'activité électrique du cerveau, reste une des meilleures méthodes de prévision non-invasive des résultats neurologiques. L'objectif de notre travail est de développer un système de classification automatique qui prévoit des risques sur la maturation cérébrale, se traduisant par un état pathologique à 2 ans. Les caractéristiques du signal EEG, qui sont utiles à la prévision automatisée, sont traitées via un module appelée EEGDiag, et sont appliquées sur un ensemble de données issues de 397 dossiers de nouveau-nés prématurés. Chaque dossier comprend un enregistrement EEG, et un rapport concernant les informations et les diagnostics de l'enfant à la naissance et 2 ans plus tard (normal, pathologique ou douteux). Pour aider les médecins à prévenir l'état neurologique anormal du nouveau-né prématuré, nous avons développé plusieurs modèles de classification qui s'appliquent sur différentes séries de caractéristiques du signal EEG inspirées des annotations des neuropédiatres. Plusieurs modèles de classification et d'aide à la décision sont testés sur différentes extractions de la base de données afin de fournir aux médecins le système de classification le plus performant. Notre système proposé permet de détecter automatiquement des pronostics sur l'état pathologique du nouveau-né prématuré. Notre travail a consisté à subdiviser l'amplitude des bouffées du signal EEG en trois catégories : faible, moyenne et forte. Cette étude de subdivision a permis de choisir les intervalles associés à ces trois catégories permettant d'augmenter considérablement la performance de notre système de classification automatique. Une analyse de corrélation a permis de détecter des relations d'indépendance et de redondance entre certaines données, ce qui permet de réduire le nombre de variables décisives et de sélectionner ainsi la meilleure série de variables qui ramènent notre système à devenir optimal et plus efficace. Ces études nous ont permis d'atteindre un système de classification automatique basé sur une série de 17 variables avec une exactitude 93.2%. Ce système peut apporter une bonne sensibilité à la prévision de l'état neurologique du nouveau-né prématuré et peut servir comme aide à la décision dans le traitement clinique.

Mots clés

Prématuré, Electroencéphalogramme, Prévision, Classification, Amplitude EEG, corrélation

Abstract

The electroencephalogram (EEG), a measure of the electrical activity of the brain, remains one of the best non-invasive methods for predicting neurological outcomes. The aim of our work is to develop an automatic classification system which predicts risks on cerebral maturation that can lead to a pathological condition at 2 years. The EEG signal characteristics, which are useful for automated prediction, are processed via an application called EEGDiag, and applied to a set of 397 records for premature infants. Each record include an EEG record and a report on infant information and diagnosis at birth and 2 years later (normal, sick or risky). To assist physicians in preventing any abnormal neurological condition of the premature newborn, we have developed several intelligent classification models which can be applied to several series of characteristics of the EEG inspired from the annotations of neuropediatricians. Several classification and decisional aid models have been tested on different extracted databases in order to offer to doctors the best efficient classification system. Our proposed system automatically detects the prognosis of the premature newborn pathological condition. Our work consisted of subdividing the amplitude of EEG signal burst into three categories: low, medium and high. This subdivision study allowed to choose Intervals of these three categories which have served to greatly increase the performance of our intelligent classification system. A correlative data analysis allowed to create an independence and redundancy relation between the data attributes, which reduces the number of decisive parameters and thus selects the best series of parameters that made our system optimal and more efficient. These studies enabled us to achieve a classification system based on a series of 17 parameters with an accuracy 93.2%. This system can provide good sensitivity on predicting the neurological status of premature newborn and can be used as a decisional aid in clinical treatment.

Key Words

Preterm, Electroencephalogram, Prediction, Classification, EEG amplitude, correlation