

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC

MÉMOIRE PRÉSENTÉ À
L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

COMME EXIGENCE PARTIELLE
À L'OBTENTION DE LA
MAÎTRISE EN GÉNIE
CONCENTRATION PERSONNALISÉE
M. Ing.

PAR
Jonathan GODBOUT

CRITÈRES SPATIAL ET SPECTRAL POUR LA DÉTECTION DES FUSEAUX DU
SOMMEIL EN EEG

MONTRÉAL, LE 15 MAI 2013



Jonathan Godbout, 2013



Cette licence [Creative Commons](#) signifie qu'il est permis de diffuser, d'imprimer ou de sauvegarder sur un autre support une partie ou la totalité de cette œuvre à condition de mentionner l'auteur, que ces utilisations soient faites à des fins non commerciales et que le contenu de l'œuvre n'ait pas été modifié.

PRÉSENTATION DU JURY

CE MÉMOIRE A ÉTÉ ÉVALUÉ

PAR UN JURY COMPOSÉ DE :

M. Jean-Marc Lina, directeur de mémoire
Département de génie électrique à l'École de technologie supérieure

Mme Julie Carrier, codirectrice de mémoire
Département de psychologie à l'Université de Montréal

M. Ghyslain Gagnon, président du jury
Département de génie électrique à l'École de technologie supérieure

Mme Catherine Laporte, membre du jury
Département de génie électrique à l'École de technologie supérieure

IL A FAIT L'OBJET D'UNE SOUTENANCE DEVANT JURY ET PUBLIC

LE 23 AVRIL 2013

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

REMERCIEMENTS

Je tiens à remercier mon directeur Jean-Marc Lina pour m'avoir offert les opportunités de travailler dans le domaine du traitement des signaux biomédicaux, de m'avoir supporté et d'avoir eu confiance en moi tout au long de mon parcours. Je remercie aussi Julie Carrier de son support et de m'avoir chaleureusement intégré dans son équipe de l'Hôpital du Sacré-Cœur de Montréal.

CRITÈRES SPATIAL ET SPECTRAL POUR LA DÉTECTION DES FUSEAUX DU SOMMEIL EN EEG

Jonathan GODBOUT

RÉSUMÉ

Les fuseaux du sommeil sont des oscillations relativement rapides d'environ une seconde qui caractérisent le stade 2 du sommeil observé en EEG. Cette activité sporadique aurait un rôle dans la protection du sommeil et les processus de mémoire et de plasticité cérébrale. Plusieurs détecteurs automatiques ont été proposés pour assister ou remplacer l'expert dans l'identification des fuseaux. La problématique persistante est que ces algorithmes détectent en général trop d'événements et que le compromis entre sensibilité (Se) et spécificité (Sp) est délicat à atteindre. Dans le présent travail, on propose un détecteur semi-automatique et supervisé qui ajoute une phase de spécificité spatiale et fréquentielle à une phase sensible basée sur des critères validés dans la littérature.

Dans la phase sensible, les événements candidats sélectionnés (bande 10Hz-16Hz) sont ceux dont les caractéristiques d'amplitude et de rapport spectral rejettent une hypothèse nulle ($p < 0.1$), soit l'événement considéré n'est pas un fuseau. Cette hypothèse nulle est construite à partir des événements se manifestant durant les stades REM identifiés par un expert. Dans la phase spécifique, une classification hiérarchique des candidats est faite sur les caractéristiques de fréquence et de position spatiale (axe antéro-postérieur). La classe sélectionnée est celle regroupant la majorité d'un ensemble de fuseaux marqués par l'expert. À la première phase, on obtient $Se = 93.2\%$ et $Sp = 89.0\%$. À la deuxième phase, on obtient $Se = 85.4\%$ et $Sp = 95.5\%$. Les résultats suggèrent que l'aspect spatio-fréquentiel est caractéristique des fuseaux et peut contribuer à perfectionner les méthodes de détection automatique.

Mots-clés : fuseaux du sommeil, détection, électroencéphalographie, temps-fréquence, classification hiérarchique.

CRITÈRES SPATIAL ET SPECTRAL POUR LA DÉTECTION DES FUSEAUX DU SOMMEIL EN EEG

Jonathan GODBOUT

ABSTRACT

Sleep spindles are short bursts of relatively high frequency oscillations occurring mainly during stage 2 sleep as observed in EEG. This sporadic activity is thought to have a role in sleep integrity protection, memory processes and plasticity. Many automatic detectors have been proposed to assist or replace the expert in the task of identifying sleep spindles. The persistent problem is that these algorithms usually detect too many events and that the compromise between sensitivity (Se) and specificity (Sp) is difficult to achieve. In this work, we propose a semi-automatic and supervised detector which adds a specificity phase, using spatial and frequency criteria, to a sensitivity phase based on proven criteria in the literature.

In the sensitivity phase, selected candidate events (10Hz-16Hz band) are those whose amplitude and spectral ratio characteristics reject a null hypothesis ($p < 0.1$), which is that the considered event is not a spindle. This null hypothesis is constructed from events occurring during REM stages identified by an expert. In the specificity phase, a hierarchical clustering of the candidates is done on the frequency and spatial position (anterior-posterior) characteristics. The selected class is the one grouping the majority of a set of spindles marked by an expert. In the first phase, we obtain $Se = 93.2\%$ and $Sp = 89.0\%$. In the second phase, we obtain $Se = 85.4\%$ and $Sp = 95.5\%$. Results suggest that spatio-frequency criteria are characteristic to spindles and can help improve automatic detection methods.

Keywords : sleep spindles, detection, electroencephalography, time-frequency, hierarchical clustering.

TABLE DES MATIÈRES

	Page
INTRODUCTION	1
CHAPITRE 1 MISE EN CONTEXTE	3
1.1 L'électroencéphalographie (EEG)	3
1.2 Sommeil	6
1.3 Fuseaux	9
CHAPITRE 2 ÉTAT DE L'ART	13
2.1 Détection automatique des fuseaux: les premiers travaux	13
2.2 Les détecteurs à fonction de détection	14
2.2.1 Fonction de détection	16
2.2.2 Fonction de seuillage	17
2.2.3 Régularisation	19
2.3 Les détecteurs à classification paramétrique	21
2.3.1 Segmentation	23
2.3.2 Extraction des caractéristiques	23
2.3.3 Classification	26
2.4 Approches multicanaux	28
2.5 Évaluation de la performance	30
2.6 Objectifs du présent travail	33
CHAPITRE 3 MÉTHODOLOGIE	35
3.1 Montage de détection	35
3.2 La transformée en ondelettes continue (CWT)	38
3.3 Fonction de détection temps-fréquence	41
3.4 Segmentation adaptative	43
3.5 Extraction des caractéristiques	45
3.5.1 Amplitude	45
3.5.2 Rapport spectral sigma	45
3.5.3 Stade de sommeil	47
3.5.4 Fréquence	48
3.5.5 Position médiane	48
3.5.6 Expert	51
3.6 Sélection sensible: seuillage par <i>p-value</i>	51
3.7 Sélection spécifique: classification hiérarchique	54
3.8 Résumé de la méthode	58
3.9 Évaluation de la performance	59
CHAPITRE 4 RÉSULTATS	61
4.1 Marquage de l'expert: sommeil et fuseaux	61
4.2 Montage de détection	63

4.3	Segmentation adaptative	63
4.4	Sélection sensible: seuillage par <i>p-value</i>	63
4.5	Sélection spécifique: classification hiérarchique	67
4.5.1	Quelle est l'importance du nombre de fuseaux identifiés par l'expert?	69
4.6	Caractéristiques des fuseaux détectés	71
4.6.1	Fréquence et position médiane	71
4.6.2	Fuseaux moyens	73
4.6.3	Quantité de fuseaux à travers les cycles de sommeil	76
CHAPITRE 5 DISCUSSION		79
5.1	Montage de détection	79
5.2	Segmentation adaptative	80
5.3	Sélection sensible: seuillage par <i>p-value</i>	81
5.4	Sélection spécifique: classification hiérarchique	84
5.5	Caractéristiques des fuseaux détectés	86
5.6	Rôle de l'expert	88
CONCLUSION		91
5.7	Contributions originales	91
5.8	Principaux résultats	92
5.9	Perspectives	93
ANNEXE I FORMALISME SUR LA NOTION D'ÉVÈNEMENT		95
ANNEXE II MARQUAGE DE L'EXPERT: SOMMEIL ET FUSEAUX		97
ANNEXE III ÉVÈNEMENTS DÉTECTÉS		99
ANNEXE IV PERFORMANCE		101
LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES		103

LISTE DES FIGURES

	Page	
Figure 1.1	Systèmes de positionnement 10-20 et 10-10 des électrodes EEG	5
Figure 1.2	Stades et architecture du sommeil	8
Figure 1.3	Signal EEG contenant deux fuseaux (barres)	9
Figure 1.4	Mécanisme de génération du fuseau	11
Figure 2.1	Schéma de détection par fonction de détection	15
Figure 2.2	Schéma de détection par classification paramétrique	22
Figure 3.1	Illustration de l'utilisation de montages	37
Figure 3.2	Effet des paramètres β et γ de l'ondelette de Morse généralisée	41
Figure 3.3	Illustration de la génération de la fonction de détection	42
Figure 3.4	Illustration de la segmentation de la fonction de détection	44
Figure 3.5	Illustration de l'extraction du rapport spectral sigma	47
Figure 3.6	Position des capteurs sur un plan virtuel au-dessus de la tête en termes de coordonnées médianes (ordonnées) et de coordonnées latérales (abscisses) ...	50
Figure 3.7	Illustration de l'obtention des seuils pour l'étape de pré-détection	52
Figure 3.8	Illustration de la classification ascendante hiérarchique (CAH)	56
Figure 4.1	Structure du sommeil des neuf sujets de la base de données	62
Figure 4.2	Distributions des caractéristiques utilisées dans la première phase de détection	64
Figure 4.3	Performance en première phase de détection	66
Figure 4.4	Résultats de classification ascendante hiérarchique (CAH)	68
Figure 4.5	Différentiel des mesures de performance pour un marquage partiel, par rapport à un marquage exhaustif, en fonction du nombre de fuseaux marqués par l'expert	70

Figure 4.6	Distributions jointes des caractéristiques de fréquence et de position médiane pour tous les sujets (S1 à S9)	72
Figure 4.7	Grande moyenne à travers les sujets	75
Figure 4.8	Distribution de la quantité de fuseaux à travers les cycles de sommeil	77

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

AR	Modèle autorégressif
CAH	Classification ascendante hiérarchique
CDF	Fonction de répartition (<i>Cumulative Distribution Function</i>)
CWT	Transformée en ondelettes continue (<i>Continuous Wavelet Transform</i>)
PDF	Densité de probabilité (<i>Probability Density Function</i>)
DWT	Transformée en ondelettes discrète (<i>Discrete Wavelet Transform</i>)
EEG	Électroencéphalographie
EMD	Décomposition modale empirique (<i>Empirical Mode Decomposition</i>)
FN	Faux négatif
FP	Faux positif
MP	<i>Matching Pursuit</i>
R&K	Règles de Rechtschaffen et Kales (1968)
RMS	Valeur efficace (<i>Root Mean Square</i>)
ROC	<i>Receiver Operating Chararcteristic</i>
STFT	<i>Short Time Fourier Transform</i>
SVD	Décomposition en valeurs singulières (<i>Singular Value Decomposition</i>)
UPGMA	Liaison moyenne (<i>Unweighted Pair Group Method with Arithmetic Mean</i>)
VN	Vrai négatif
VP	Vrai positif
WPT	Paquets d'ondelettes (<i>Wavelet Packet Transform</i>)

LISTE DES SYMBOLES ET UNITÉS DE MESURE

Hz Hertz (cycle par seconde)

ms milliseconde

sec seconde

μ V microvolt

V Volt

W Watt

INTRODUCTION

Nous dormons près du tiers de notre vie à raison de huit heures par jour en moyenne. Le sommeil, qui est l'état naturel associé à cette action de dormir, a un rôle évident pour la santé physique et mentale. Or, bien des mystères règnent encore sur ses fonctions et mécanismes biologiques. L'élucidation de ces mystères pourra mener à une meilleure compréhension et donc une meilleure gestion des troubles du sommeil, entre autres par rapport aux effets du vieillissement. Avec l'avènement de l'électroencéphalographie (EEG), qui enregistre sur le scalp les potentiels électriques générés par le cerveau, il a vite été observé que le sommeil est caractérisé par des rythmes particuliers qui diffèrent de l'état d'éveil. L'EEG est ainsi une porte d'entrée vers les processus neurophysiologiques du sommeil.

Une entité observée sur l'EEG qui a attiré beaucoup d'attention est le fuseau du sommeil, une oscillation relativement rapide d'environ une seconde, se manifestant pendant le sommeil léger. Le fuseau, qui résulte de l'interaction entre le thalamus et le cortex cérébral, pourrait avoir un rôle clé dans, entre autres, les processus de mémoire et de protection du sommeil. Il importe donc de les identifier dans les tracés EEG afin de les caractériser et d'étudier comment ils peuvent varier selon des états biologiques particuliers, pathologiques ou non. Traditionnellement, cette identification est faite visuellement par un expert entraîné à lire et interpréter les signaux EEG. De par la quantité considérable de fuseaux dans une nuit complète et leur relative subtilité dans les signaux, cette tâche manuelle demande un effort considérable, potentiellement immense pour une cohorte de sujets. Il y a ainsi un besoin de détecteurs automatiques de fuseaux, électroniques ou logiciels, qui identifie automatiquement les fuseaux selon des règles imitant au mieux l'expert humain.

Les premières formes de détecteurs automatiques sont apparues dans les années soixante-dix, utilisant des méthodes de filtrages analogiques. Depuis l'avènement des ordinateurs modernes, les méthodes numériques et logicielles ont été favorisées. À ce jour, une panoplie de méthodes issues du traitement de signal et des systèmes experts ont été appliquées à cette problématique. Or, à l'issue de tous ces travaux, le problème persistant est la difficulté à

trouver un compromis entre sensibilité et spécificité de détection ; par rapport à des fuseaux visuellement marqués par un expert, un détecteur automatique trouve une quantité considérable d'événements supplémentaires.

Le but du présent travail est de proposer une solution à ce problème de spécificité. À une première phase de détection temps-fréquence très sensible inspirée de la littérature, on ajoute une deuxième phase de classification formant des groupes d'événements qui se ressemblent sur des critères de fréquence d'oscillation et de position spatiale sur le scalp. Cette classification spatio-fréquentielle nouvelle est motivée par l'évidence d'une dichotomie des fuseaux : ceux se manifestant dans les régions frontales seraient plus lents et ceux se manifestant dans les régions centrales et pariétales seraient plus rapides. Le choix supervisé d'une classe particulière regroupant le plus d'événements marqués par un expert a comme objectif de rendre plus spécifique la sélection des événements considérés comme fuseaux par le détecteur.

Le présent travail est présenté en cinq chapitres. Le premier chapitre met le lecteur en contexte de la problématique en présentant brièvement l'EEG, le sommeil et les fuseaux. Le deuxième chapitre présente l'état de l'art de la détection automatique des fuseaux dans l'EEG sous la forme d'une revue de littérature. Le troisième chapitre décrit la méthodologie utilisée dans le présent travail en présentant les outils temps-fréquence et la classification hiérarchique. Le quatrième chapitre présente les résultats obtenus pour chaque phase de détection des fuseaux et de leur performance. Enfin, le cinquième chapitre consiste en une discussion sur les performances obtenues et l'interprétation des classes de fuseaux obtenues.

CHAPITRE 1

MISE EN CONTEXTE

1.1 L’electroencéphalographie (EEG)

L’electroencéphalographie (EEG) est une technique non-invasive d’investigation de l’activité électrophysiologique cérébrale. Elle consiste en l’enregistrement du potentiel électrique mesuré sur le scalp, ou le cuir chevelu, à l’aide d’électrodes. Les *sources* de cette activité électrique mesurable sont les neurones, principalement les cellules pyramidales situées dans la matière grise du cerveau. Du point de vue bioélectrique, le neurone est considéré comme l’élément de base du cerveau. Il est principalement constitué du *corps* (ou *soma*, contenant le noyau de la cellule), de *dendrites* (multiples arborescences qui reçoivent les potentiels d’action des autres neurones) et d’un *axone* (simple branche qui transmet le potentiel d’action vers d’autres neurones). La matière grise du cerveau contient principalement les corps cellulaires, tandis que la matière blanche est surtout constituée des axones.

Comme toute cellule, le neurone est enveloppé d’une membrane polarisée, avec une différence de potentiel électrique entre le milieu interne et le milieu externe, mesurée en millivolt (mV). Par convention, la référence (ou mise à la terre, par analogie au domaine de l’électricité) correspond au milieu externe. Par des mécanismes passifs et actifs de transferts d’ions (correspondant à des charges électriques, positives et négatives), la membrane d’un neurone possède un potentiel de repos à environ -70mV en équilibre électrochimique. L’interaction du neurone avec son environnement amène son potentiel de membrane à varier autour de son potentiel de repos; on parle de dépolarisation et d’hyperpolarisation (Marieb et Lachaîne, 2005).

Si la dépolarisation cause le dépassement d’un seuil (de l’ordre de -50mV), un *potentiel d’action* (PA) est déclenché. Un PA est une brusque inversion de polarité d’environ 100mV (de -70mV à +30mV). Ce phénomène, qui dure quelques millisecondes (ms), est transmis le long de l’axone jusqu’aux synapses. La synapse est un mince espace de jonction entre deux

neurones qui peut être de deux types : chimique ou électrique (moins abondante). La synapse chimique se compose de trois parties : la membrane présynaptique (bouton axonal du neurone d'où provient le PA et qui contient des neurotransmetteurs), la fente synaptique (espace extracellulaire où les neurotransmetteurs sont relâchés par le PA) et la membrane postsynaptique (dendrite ou corps du neurone récepteur) (Marieb et Lachaîne, 2005).

Le signal EEG n'est pas dû aux PA; il résulte plutôt du grand nombre de courants postsynaptiques des neurones pyramidaux. Les courants excitateurs postsynaptiques (EPS) ont un effet dépolarisateur, tandis que les courants inhibiteurs postsynaptiques (IPS) ont un effet hyperpolarisateur. En somme, la distribution des charges transforme le neurone pyramidal en dipôle électrique. Celui-ci engendre un courant primaire à l'intérieur du neurone et des courants secondaires se propageant dans le milieu purement résistif constitué par, entre autres, le tissu nerveux, le crâne et le scalp. Ce sont ces courants secondaires, à l'échelle de population de neurones synchronisés, qui génèrent les potentiels mesurés par les électrodes EEG. De plus, l'orientation des dendrites des neurones pyramidaux (perpendiculaire par rapport à la surface du cortex) fait en sorte que nous observons principalement les EPS et IPS de cette couche particulière de neurones du cerveau (Benbadis et al., 2007; Sanei et Chambers, 2007).

Les systèmes d'acquisition EEG les plus communs utilisent des électrodes en argent pur (Ag) recouvert d'une mince couche de chlorure d'argent (AgCl). Elles consistent en des disques de quelques millimètres de diamètre qui sont fixées sur le scalp à l'aide d'un gel conducteur. Une pâte abrasive peut aussi être utilisée pour nettoyer les points de contact sur le scalp et diminuer l'impédance. Ces électrodes sont reliées par des câbles à un amplificateur. Les signaux analogiques amplifiés sont ensuite numérisés, i.e. filtrés, échantillonnés, quantifiés et encodés. Un paramètre important est la fréquence d'échantillonnage f_e , en unités Hertz (Hz) ou nombre d'échantillons par seconde, qui fixe la résolution temporelle et le contenu spectral accessible¹. Puisque les rythmes d'intérêt sont habituellement inclus dans la bande 0Hz-

¹ Le théorème de Nyquist stipule que la fréquence maximale accessible est $f_e/2$, où f_e est la fréquence d'échantillonnage.

100Hz, une fréquence f_e d'au moins 200Hz est souvent suffisante, mais dans des cas particuliers elle peut atteindre quelques milliers de Hz (Sanei et Chambers, 2007).

La position des électrodes sur le scalp respecte une norme internationale connue sous le nom de système 10-20. Elle est basée sur des points de référence anatomiques faciles à localiser : le nasion, l'inion et les points préauriculaires. Les positions des électrodes sont obtenues en divisant les distances, en circonférence, entre le nasion et l'inion et entre les points préauriculaires en intervalles de 10% et 20% (voir Figure 1.1 A et B). Une extension de ce système, le système 10-10, n'utilise que des intervalles de 10%, augmentant le nombre d'électrodes (Figure 1.1 C) (Benbadis et al., 2007; Malmivuo et Plonsey, 1995)

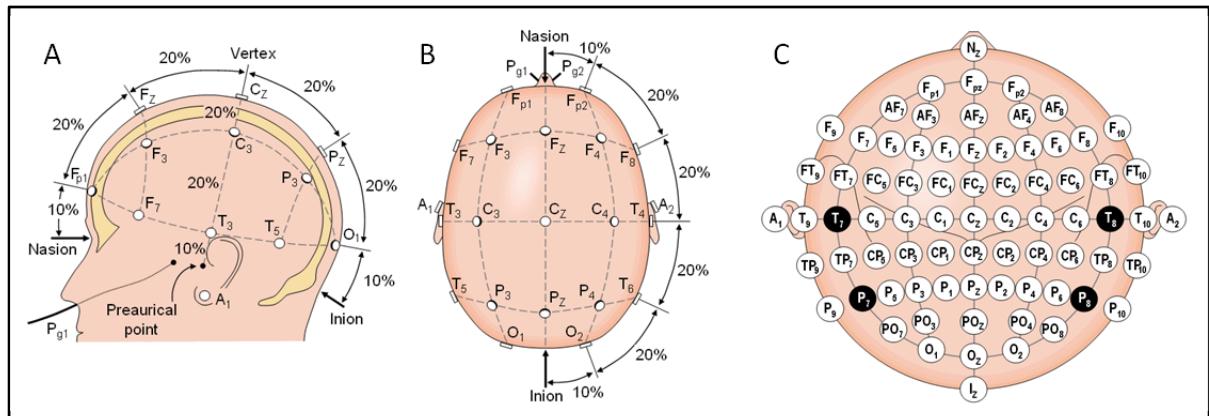


Figure 1.1 Systèmes de positionnement 10-20 et 10-10 des électrodes EEG
A: Vue de profil. B: Vue de dessus. C: Système 10-10, avec en noir les électrodes dont les noms diffèrent du système 10-20
(Tirée de Malmivuo et Plonsey, 1995, p.258)

Le nom des électrodes est aussi standard. Il commence par une ou deux lettres qui renseignent sur la région : Fp (frontopolaire), F (frontal), C (central), P (pariétaire), O (occipital), T (temporal) et A (auriculaire). Il est suivi d'un nombre qui augmente en s'éloignant de la ligne médiane. Les nombres pairs correspondent à l'hémisphère droit et les nombres impairs correspondent à l'hémisphère gauche. Pour la ligne médiane, la lettre *z* est

utilisée à la place d'un nombre. En passant du système 10-20 au système 10-10, T3/T4 devient T7/T8 et T5/T6 devient P7/P8 (Benbadis et al., 2007).

Une méthode couramment utilisée pour l'étude des signaux EEG est l'analyse spectrale, i.e. l'analyse du contenu en fréquence de l'activité cérébrale. Il est d'usage de décomposer le spectre en bandes fréquentielles, basées sur l'observation de rythmes naturels observables dans différents états : le rythme alpha (α , 8Hz-13Hz), observable dans la région occipitale d'un sujet éveillé ayant les yeux fermés; le rythme bêta (β , 13Hz-30Hz), observable à l'éveil avec les yeux ouverts; le rythme delta (δ , 0.5Hz-4Hz), observable chez le nouveau-né et dans le sommeil adulte; le rythme thêta (θ , 4Hz-8Hz), observable chez l'enfant et dans le sommeil adulte (Malmivuo et Plonsey, 1995). Les rythmes au-delà de 30Hz constituent la bande gamma (γ , > 30Hz). La borne supérieure de cette bande n'est pas clairement définie, mais la plus communément admise se situe autour de 100Hz (Niedermeyer et Da Silva, 2005).

1.2 Sommeil

Le sommeil est un état physiologique naturel réversible qui se caractérise par une quiescence comportementale : réduction ou absence de mouvements, diminution de réaction à des stimuli externes, position couchée du corps, yeux fermés et rythme respiratoire ralenti et régulier (Lee-Chiong, 2008). L'humain passe près du tiers de sa vie dans cet état, à raison de 6 à 9 heures par jour pour une moyenne de 8 heures. La fonction du sommeil reste à ce jour source de débats, mais semble avoir un rôle pour, entre autres, l'anabolisme, la thermorégulation, la défense immunitaire, la consolidation de la mémoire et la plasticité cérébrale (Lee-Chiong, 2008).

On divise le sommeil en deux grands états : le sommeil à mouvements oculaires rapides (*Rapid Eye Movement, REM*) et le sommeil sans REM, ou non-REM (NREM ou sommeil lent). Le sommeil lent NREM se divise lui-même en 4 stades, selon la profondeur du sommeil. Les stades 1 et 2 constituent le sommeil lent léger et les stades 3 et 4 constituent le sommeil lent profond. Les stades 3 et 4 peuvent être groupés en un seul stade de sommeil lent profond (*Slow Wave Sleep, SWS*). Chez le jeune adulte, le sommeil compte environ 2%-

5% de stade 1, 45%-55% de stade 2, 10% de stade 3, 10% de stade 4 et 25% de stade REM. L'identification des stades de sommeil se base principalement sur l'EEG, mais inclut également l'information d'autres modalités, comme l'électro-oculogramme (EOG) pour le mouvement des yeux et l'électromyogramme (EMG) pour l'activité musculaire (surtout le menton). L'électrocardiogramme (ECG) peut également être enregistré pour décrire le rythme cardiaque. L'acquisition de tous ces signaux définit la polysomnographie (Lee-Chiong, 2008).

La Figure 1.2 A montre des exemples de tracés EEG pour différents états en lien avec le sommeil. L'éveil avec les yeux ouverts est caractérisé par de l'activité rapide et de faible amplitude (13Hz et plus). Lorsque les yeux sont fermés, l'activité est dominée par le rythme α (8Hz-13Hz). Le stade 1 est principalement caractérisé par des *roulements* lents des yeux observables sur l'EOG, une diminution du rythme α et la présence de rythme θ (4Hz-8Hz). À ce stade, le sujet est réveillé facilement. Le stade 2 est caractérisé par la présence de fuseaux (oscillations entre 10Hz et 16Hz durant environ une seconde, *voir* section 1.3), avec présence possible de rythme δ (0.5Hz-4Hz, moins de 20%). Les stades 3 et 4 sont principalement caractérisés par le rythme δ (de 20% à 50% en stade 3, > 50% en stade 4), avec présence possible de fuseaux. Le sujet est réveillé difficilement.

Le stade REM est principalement caractérisé par une activité de relativement faible amplitude mélangeant les rythmes θ (4Hz-8Hz) et β (13Hz-30Hz) et pouvant avoir une allure en «dents de scie». Il peut être décomposé en une phase phasique et une autre tonique, avec et sans mouvements oculaires rapides, respectivement. Des périodes de rythmes α peuvent être observées, mais ayant une fréquence de 1Hz à 2Hz plus basse que le rythme α observé pendant l'éveil et le stade 1. L'EMG montre une atonie musculaire. Bien que les rêves se manifestent aussi en sommeil NREM, les rêves les plus vivides et complexes se manifestent principalement en sommeil REM (Lee-Chiong, 2008).

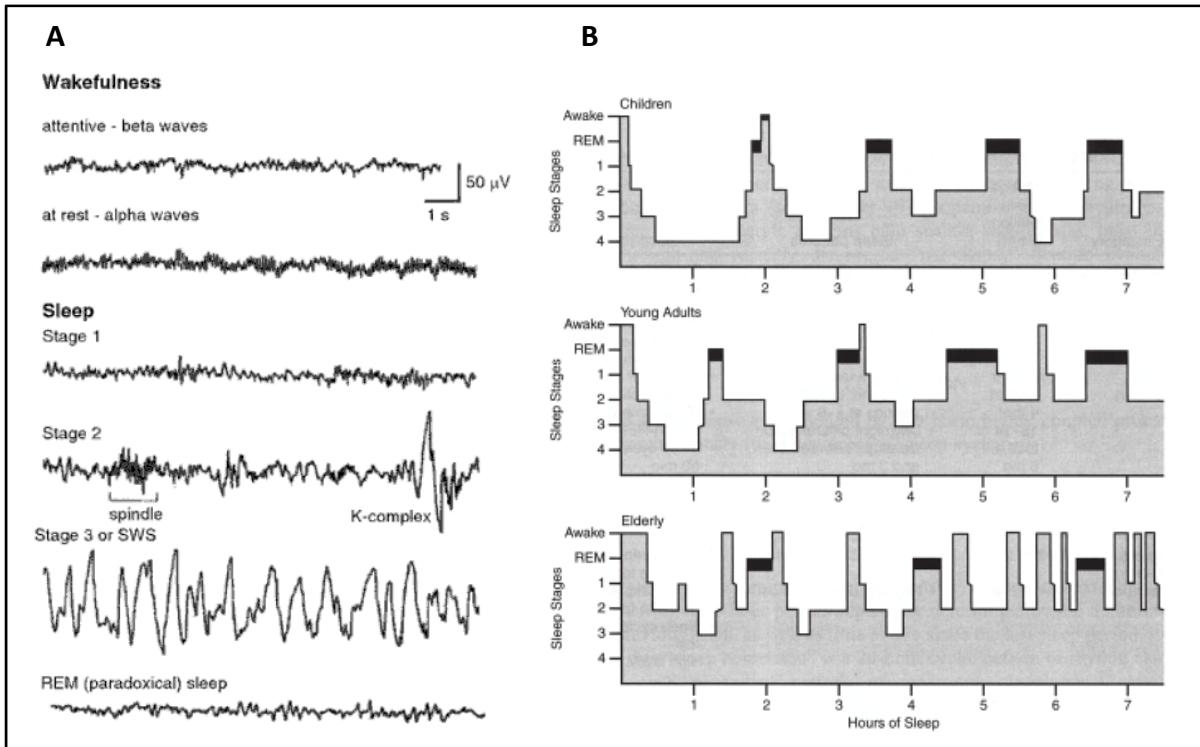


Figure 1.2 Stades et architecture du sommeil

A: Tracés EEG exemplaires de chaque stade

B: Hypnogrammes d'enfant, de jeune adulte et d'adulte âgé

(Tirée de Mindell et Owens, 2009, p.5) et (Tirée de Morin et Espie, 2012, p.16)

Un cycle de sommeil correspond à la manifestation successive de sommeil NREM et de sommeil REM. Typiquement, un cycle dure entre 90 et 120 minutes chez l'adulte et autour de 60 minutes chez le jeune enfant et le nouveau-né. Ainsi, le sommeil de l'adulte moyen compte entre trois et cinq cycles par nuit. La structure de sommeil est représentée sous forme d'un hypnogramme, un graphique correspondant à la séquence des stades au cours de la nuit (*voir* Figure 1.2 B). Celui-ci permet de quantifier la contribution de chaque stade au cours de chaque cycle et de mesurer l'évolution des cycles au cours de la nuit. Le pourcentage de SWS est plus élevé dans les premiers cycles, tandis que le pourcentage de REM est plus élevé dans les derniers cycles. Enfin, l'effet du vieillissement sur l'architecture de sommeil inclut une diminution de sa durée totale, de son efficacité (rapport du temps de sommeil et du

temps au lit), du pourcentage de SWS et de REM, et une augmentation du taux d'éveil (Lee-Chiong, 2008).

1.3 Fuseaux

Le fuseau du sommeil (*sleep spindle*) est une oscillation transitoire se manifestant principalement en stade 2. La bande fréquentielle dans laquelle il se manifeste se trouve à la jonction des bandes α et β et est connue sous le nom de bande sigma (σ). Bien qu'observé et décrit depuis les premiers enregistrements EEG, la première définition formelle du fuseau date de 1968, où il était défini comme toute activité entre 12Hz et 14Hz (Rechtschaffen et Kales, 1968). Cette définition a été mise à jour en 2007 pour désigner tout train d'onde entre 11Hz et 16Hz, particulièrement entre 12Hz et 14Hz, d'une durée d'au moins 0.5 seconde et d'amplitude maximale sur les dérivations centrales, i.e. les électrodes situées près du centre de la surface du scalp (Iber et al., 2007). La Figure 1.3 illustre des exemples de fuseaux dans le signal EEG.

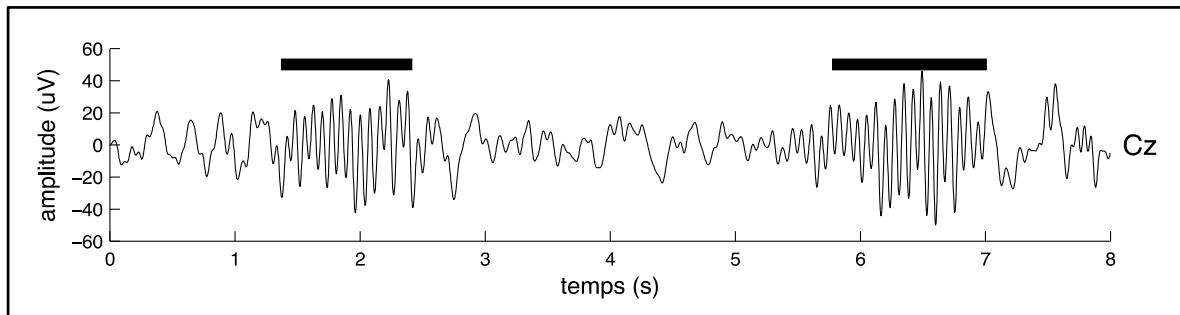


Figure 1.3 Signal EEG contenant deux fuseaux (barres)

Le mécanisme neurophysiologique de génération du fuseau a principalement été mis en lumière par la contribution remarquable de Mircea Steriade (1924-2006) et ses collaborateurs au cours des deux dernières décennies du siècle passé. Ces travaux, consistant en des enregistrements intracellulaires chez le chat, ont montré que le fuseau résulte de l'interaction entre le système réticulaire, le thalamus et le cortex. Les neurones réticulaires (RE), qui se

mettent à osciller, transmettent des courants postsynaptiques rythmiques inhibiteurs sur les neurones thalamocorticaux (Th-Cx, neurones du thalamus projetant des efférences vers le cortex). Le rebond postinhibition des neurones Th-Cx cause des efférences excitatrices chez les neurones corticaux (Cx). Le retour d'activité de Cx vers RE et Th-Cx forme une boucle thalamocorticale-corticothalamique responsable de la synchronisation de l'activité rythmique dans tout le système (De Gennaro et Ferrara, 2003). La Figure 1.4 A montre la configuration du système responsable de la génération du fuseau impliquant les neurones RE, Th-Cx et Cx. La Figure 1.4 B montre de l'activité de fuseau mesurée en EEG de surface et la Figure 1.4 C montre un fuseau dans des enregistrements intracellulaires chez le chat. On y voit comment les neurones RE engendrent une inhibition sur les neurones Th-Cx, dont le rebond génère des potentiels d'action excitateurs vers les neurones Cx.

Plusieurs observations se sont accumulées pour suggérer l'existence de deux types de fuseaux : un type plus rapide (autour de 14Hz) localisé sur les dérivations centrales et un type plus lent (autour de 12Hz) localisé sur les dérivations frontales (De Gennaro et Ferrara, 2003). Cette dichotomie, étant à ce jour encore source de débats, pourrait être issue d'un seul mécanisme, comme la durée du rebond d'hyperpolarisation des neurones Th-Cx, ou impliquer deux mécanismes fonctionnellement distincts (De Gennaro et Ferrara, 2003).

La prévalence des fuseaux, mesurée par la densité d'événements discrets ou la puissance dans la bande σ , est maximale en stade 2, mais peut être modulée par certains facteurs. Il a été observé qu'elle augmente au cours de la nuit (de cycle en cycle), qu'elle diminue après une nuit de privation de sommeil (l'effet étant observable principalement durant le premier cycle) et qu'elle est synchronisée au cycle circadien. Une relation réciproque entre la bande σ et la bande δ (0.5Hz-4Hz, associé au SWS) a aussi été observée, montrant des anticorrelations entre autres à l'intérieur des cycles, au cours de la nuit et suite à des privations de sommeil (De Gennaro et Ferrara, 2003). Le vieillissement a comme principaux effets de diminuer la densité, la durée et l'amplitude des fuseaux, avec une légère augmentation de la fréquence d'oscillation. Il a récemment été montré que ces effets

pourraient être spécifiques spatialement, que chacune de ces caractéristiques serait affectée différemment par le vieillissement selon la position sur le scalp (Martin et al., 2012).

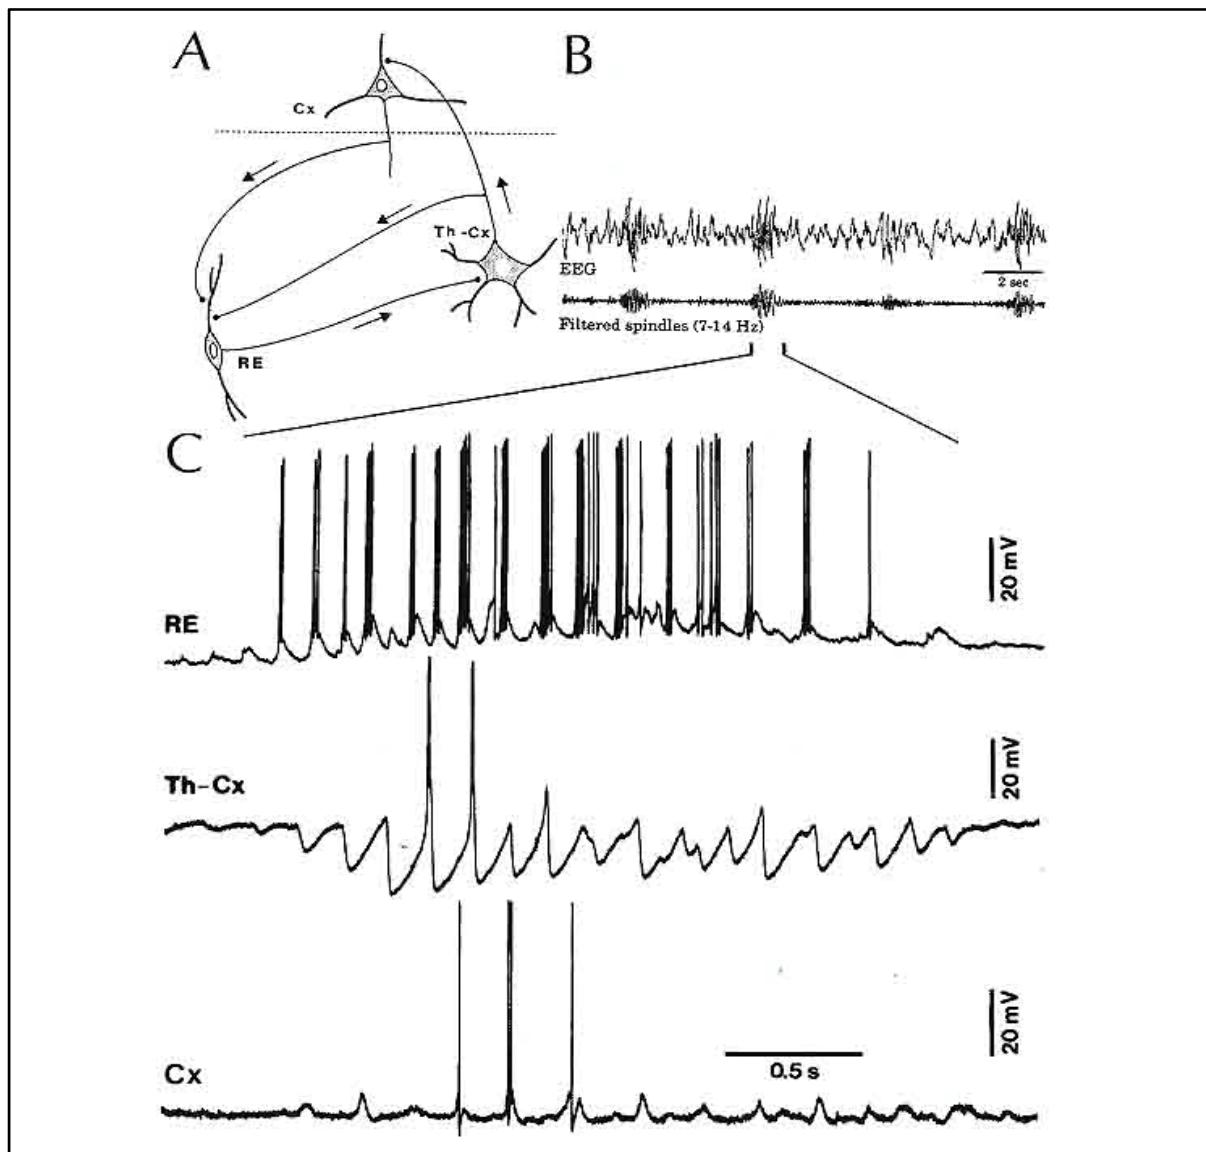


Figure 1.4 Mécanisme de génération du fuseau
 A: Interactions entre neurones réticulaires (RE), thalamocorticaux (Th-Cx) et corticaux (Cx)
 B: Signaux EEG bruts et filtrés. C: Enregistrements intracellulaires
 (Tirée de Steriade, 2003, p.881)

De par l'implication du système thalamique dans le mécanisme du fuseau, un des premiers rôles attribués aux fuseaux a été de protéger le sommeil contre les stimuli externes en bloquant les afférences sensorielles, évitant qu'elles se rendent aux cortex (De Gennaro et Ferrara, 2003; Steriade, 2006). La littérature plus récente suggère que l'activité de fuseau implique des régions associées à l'intégration de la mémoire (Schabus et al., 2007) et qu'elle augmente après apprentissage (Barakat et al., 2011).

CHAPITRE 2

ÉTAT DE L'ART

2.1 Détection automatique des fuseaux: les premiers travaux

L'EEG a permis l'étude électrophysiologique du sommeil. Les fuseaux se sont manifestés sur les premiers enregistrements et ont rapidement été reconnus comme événements importants dans la structure du sommeil. Ces entités ont formé un concept devenu un sujet d'investigation privilégié pour comprendre les mécanismes et fonctions du cerveau dormant. Leur étude a mené à la nécessité de les *marquer* dans les tracés EEG.

Cette détection visuelle, presque routinière pour un expert de l'EEG souvent complexe du sommeil, fait appel à la faculté de la perception visuelle de discerner, dans un signal, une courte oscillation relativement rapide sur un fond d'oscillations relativement lentes. C'est cette propriété holistique des fuseaux, ou gestaltique (Babadi et al., 2012; De Gennaro et Ferrara, 2003), qui a permis leur découverte sur les premiers tracés EEG.

Le perfectionnement de l'électronique et des méthodes de traitement des signaux analogiques, dans la deuxième moitié du vingtième siècle, a suscité l'espoir que ces technologies pourraient assister, voire même dépasser, l'œil humain dans la détection d'oscillations dans les signaux EEG. On peut remonter aux années 1970 pour trouver les premières formes de détection automatisée des fuseaux du sommeil se basant sur les règles de R&K (Rechtschaffen et Kales, 1968).

Dans (Sciarretta et Bricolo, 1970), des filtres analogiques sont utilisés pour extraire les harmoniques autour de 8Hz (représentant l'activité alpha) et 13Hz (représentant l'activité de fuseau). Un module intégrateur précédé d'un module redresseur permettait d'extraire l'énergie de chaque harmonique. Un fuseau automatiquement détecté débutait quand l'énergie à 13Hz dominait celle à 8Hz pendant 250ms et se terminait à la fin de cette prévalence. D'autres travaux ont suivi, explorant diverses techniques d'analyse et exploitant

surtout les développements dans le domaine des télécommunications, particulièrement adaptés à l'étude spectrale des signaux. Les systèmes de boucle verrouillée en phase (de l'anglais *phase locked loop*, PLL), utilisés dans (Broughton et al., 1978), et la démodulation complexe (de l'anglais *complex demodulation*, CD), utilisée dans (Kumar, Hofman et Campbell, 1979), ont montré leur capacité, en tant que méthodes d'analyse, de détecter des fuseaux dans les signaux EEG. Faisant suite à l'apparition embryonnaire des ordinateurs modernes dans les années 1980, les années 1990 ont vu se développer en grand nombre les applications de l'analyse numérique logicielle des signaux dans tous les domaines des sciences et de l'ingénierie. Le domaine spécifique de la détection automatique des fuseaux a su profiter de cette profusion de méthodes d'analyse.

Pour tenter de mieux comprendre la variété d'algorithmes de détection développés jusqu'à maintenant, on définit deux classes de détecteur : les détecteurs à fonction de détection et les détecteurs à classification paramétrique. Les deux sections suivantes présentent ces classes et situent les travaux de la littérature par rapport à ces deux modèles.

2.2 Les détecteurs à fonction de détection

Dans cette classe de détecteur, $s(t)$ est le signal EEG brut contenant potentiellement des fuseaux (Figure 2.1, A) et t la variable temporelle. On définit une opération $F: s(t) \rightarrow d(t)$ qui fait correspondre à $s(t)$ une fonction de détection $d(t)$, représentant une mesure de ce qui est considéré comme de l'activité *potentielle* de fuseau (Figure 2.1, B). Une fonction de seuillage $\tau(t)$ permet de créer un ensemble \tilde{X} d'évènements \tilde{x}_n , i.e. des segments du domaine t qu'on associe à de l'activité de fuseau (Figure 2.1, C, en haut). Une opération $R: \tilde{X} \rightarrow X$ permet de régulariser l'ensemble \tilde{X} sur un critère de durée, ou autre, pour donner l'ensemble X final des évènements x_n : les fuseaux détectés (Figure 2.1, C, en bas).

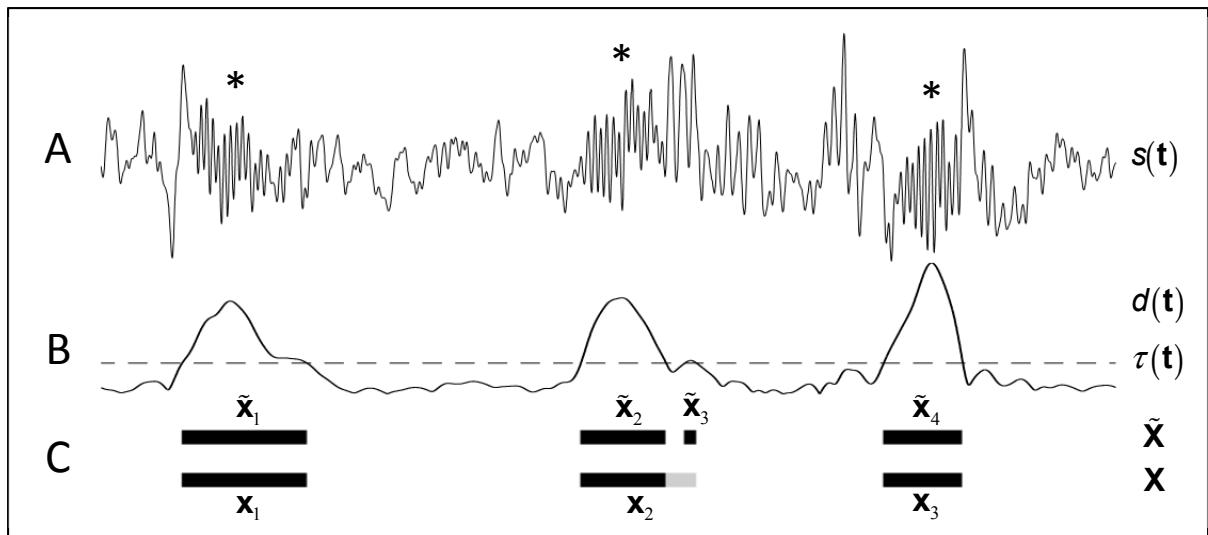


Figure 2.1 Schéma de détection par fonction de détection

A: Signal EEG contenant trois fuseaux (*). B: Fonction de détection et seuil (ligne pointillée). C: Évènements créés avec régularisation

Ce modèle de détection est intuitif et permet d'appliquer directement les règles de R&K : l'opérateur F serait un filtre dont la sortie $d(t)$ correspond à l'enveloppe des oscillations dans la bande de 12Hz à 14Hz, $\tau(t)$ serait une amplitude constante (par exemple, une estimation de l'écart-type de l'activité de fond) et la régulation R serait de garder les \tilde{X}_n dont la durée est d'au moins 500ms. Ainsi, \mathbf{X} serait un ensemble de fuseaux répondant aux règles de R&K (Rechtschaffen et Kales, 1968).

Le détecteur de (Sciarretta et Bricolo, 1970) est de cette classe. L'opérateur F consiste à extraire l'énergie des harmoniques à 8.2Hz et 13.2Hz (en filtrant, redressant et intégrant) et à les soustraire; $d(t)$ est donc positif quand l'harmonique 13.2Hz domine et négatif quand celle à 8.2Hz domine. Dans ce cas, le seuil $\tau(t)$ est simplement 0 et la régularisation R consiste à débuter le marquage seulement quand $d(t)$ est positif sur une durée d'au moins 250ms.

La première étape dans ce type de détecteur est de définir une transformation F du signal EEG $s(t)$ qui donne une fonction de détection $d(t)$ qui soit représentative de l'activité de

fuseau (par exemple, la puissance dans la bande fréquentielle des fuseaux) et régulière (*smooth*, sans trop de fluctuations).

2.2.1 Fonction de détection

Pour extraire les oscillations dans la bande des fuseaux, un filtre à réponse impulsionale finie (*Finite Impulse Response*, FIR), simple de conception, est souvent utilisé (Bodizs et al., 2009; Devuyst et al., 2006; Ferrarelli et al., 2007; Held et al., 2004; Huupponen et al., 2000a; Molle et al., 2002; Schabus et al., 2006; Schimicek et al., 1994). Des techniques plus modernes peuvent aussi faire ce travail : la Transformée en ondelettes continue (*Continuous Wavelet Transform*, CWT) utilisée dans (Caplan et al., 2001; Whitten et al., 2011), la Transformée en ondelettes discrète (*Discrete Wavelet Transform*, DWT) utilisée dans (Duman et al., 2009), les paquets d'ondelettes (*Wavelet Packet Transform*, WPT) utilisés dans (Ahmed, Redissi et Tafreshi, 2009) et la décomposition modale empirique (*Empirical Mode Decomposition*, EMD) utilisée dans (Causa et al., 2010).

Normalement, ces méthodes de filtrage fournissent un signal réel *oscillant*, qui ne répond pas au critère de régularité qu'on veut de $d(t)$. Toutefois, (Ferrarelli et al., 2007) utilisent une fonction irrégulière, correspondant au signal oscillant redressé ; ils contournent le problème en utilisant deux fonctions de seuil $\tau_1(t)$ et $\tau_2(t)$: la plus élevée sert à détecter et déterminer la position du maximum et la plus basse sert à déterminer les minima correspondant au début et à la fin des événements détectés.

Dans le cas échéant, on doit extraire l'enveloppe des oscillations. Certaines classes de ces filtres sont complexes (\mathbb{C}) ; le signal filtré est donc complexe (parties réelle et imaginaire ou module et phase instantanés) et $d(t)$ peut directement être le module du signal filtré. C'est le cas avec la démodulation complexe (*Complex Demodulation*, CD) dans (Kumar, Hofman et Campbell, 1979) et la CWT (Caplan et al., 2001). Sinon, la Transformée de Hilbert peut transformer un signal réel en un signal complexe, rendant disponible son module (Causa et al., 2010; Schabus et al., 2006).

D'autres méthodes utilisées ne font pas usage d'un signal complexe. Dans (Huupponen et al., 2000a), $d(t)$ correspond à la valeur maximale du signal filtré dans des segments de 1 seconde. Dans (Held et al., 2004), $d(t)$ est la différence entre le maximum et le minimum de chaque oscillation. (Bodizs et al., 2009) utilise une méthode similaire à (Sciarretta et Bricolo, 1970) : $d(t)$ est obtenu en passant une moyenne glissante (module intégrateur) d'environ 80ms (1/80ms = 12.5Hz) sur la valeur absolue (module redresseur) du signal filtré. Enfin, $d(t)$ peut être obtenu en calculant la valeur efficace (de l'anglais *Root Mean Square*, RMS) dans des courts segments de signaux filtrés (Molle et al., 2002; Schabus et al., 2007). Dans (Olbrich et Achermann, 2005), utilisant une méthodologie de filtrage différente, le signal EEG $s(t)$ est modélisé par un modèle autorégressif (AR) d'ordre 8 sur des segments d'une seconde. Ce modèle permet d'estimer les amplitudes et fréquences d'oscillateurs contenus dans le signal. $d(t)$ est ainsi l'amplitude de l'oscillateur dans la bande des fuseaux.

La fonction de détection peut aussi être d'une autre nature que l'enveloppe des oscillations dans une bande fréquentielle. Dans les travaux récents de (Babadi et al., 2012), une base spécifique aux fuseaux est estimée en appliquant la Transformée de Karhunen–Loève (KL) sur la matrice de covariance temporelle moyenne de 1231 fuseaux marqués par un expert. Les 500ms d'EEG brut de chacun de ces fuseaux sont projetées sur cette base et la distribution jointe des coefficients de projection est modélisée. Ainsi, pour tout nouveau signal EEG brut $s(t)$, une fenêtre glissante de 500ms se projette sur la *base fuseau* et les coefficients obtenus permettent de calculer $d(t)$: la probabilité bayésienne instantanée *a posteriori* de la présence d'un fuseau étant donné les coefficients de projection de la fenêtre de 500ms.

2.2.2 Fonction de seuillage

La fonction de détection $d(t)$ est continue et possède une valeur à chaque instant t_i ; en d'autres termes, elle ne dicte pas explicitement, *a priori*, où se trouvent les fuseaux. Cependant, elle est conçue de sorte que plus sa valeur à un instant t_i est élevée, plus grande est la possibilité qu'un fuseau soit présent à cet instant. Il faut donc trouver les instants t_i pour

lesquels $d(t_i)$ est *relativement* élevée. La solution la plus simple est de déterminer un seuil que $d(t)$ doit franchir pour être considérée comme de l'activité de fuseau. Dans (Schimicek et al., 1994), utilisant une fonction de détection $d(t)$ en valeur RMS, la fonction de seuil est fixée à $\tau(t) = 25\mu\text{V}$. Pour leur part, (Schabus et al., 2006) fixent $\tau(t) = 12\mu\text{V}$ pour $d(t)$ calculée par la Transformée de Hilbert.

Cependant, un seuil fixe ne prend pas en compte la variabilité inter-sujet des fuseaux qui est maintenant admise (De Gennaro et Ferrara, 2003). Plusieurs travaux ont tenté de définir une valeur fixe pour $\tau(t)$ adaptée à chaque sujet. (Molle et al., 2002) semblent le faire sans modèle spécifié explicitement, mais dans tous les cas $\tau(t) > 15\mu\text{V}$. Dans (Ferrarelli et al., 2007), qui utilisent deux seuils, la moyenne μ_s du signal filtré sur chaque capteur de chaque sujet est utilisée comme unité et les valeurs adaptatives sont respectivement $\tau_1(t) = 2\mu_s$ et $\tau_2(t) = 8\mu_s$. (Bodizs et al., 2009) se basent aussi sur la moyenne μ_s de chaque sujet, mais cette fois calculée dans le spectre autour des fréquences d'intérêt.

Pour une meilleure modélisation statistique du signal de chaque sujet, l'écart-type σ peut aussi être intégré dans $\tau(t)$. Ainsi, le seuil est défini comme $\tau(t) = \mu_s + 2\sigma_s$ dans (Devuyst et al., 2006). Dans leur étude, (Ray et al., 2010) utilisent plutôt la moyenne μ_a et l'écart-type σ_a de l'amplitude de quelques fuseaux (15 dans les première et deuxième moitiés de la nuit) marqués par un expert sur chaque sujet. Ils définissent ainsi comme seuil optimal $\tau(t) = \mu_a - 1.96\sigma_a$.

Une autre méthode statistique est l'approche par centile. Contrairement à l'approche relative par moment (μ_s et σ_s), le centile correspond à une quantité en pourcentage du nombre total de l'échantillon. Ainsi, dans (Schabus et al., 2007), $\tau(t)$ est défini comme le 95^{ème} centile de $d(t)$, la valeur RMS sur des segments de 250ms du signal filtré. Le détecteur de (Caplan et al., 2001), repris par (Whitten et al., 2011), utilise la CWT comme $d(t)$ dont chaque fréquence est modélisée par une distribution $\chi^2(2)$; le seuil $\tau(t)$ est ainsi définie comme le 95^{ème} centile de cette distribution, pour chaque fréquence.

Pour des $d(t)$ autres qu'une mesure de l'activité dans une bande fréquentielle, un seuil $\tau(t)$ fixe universel peut être plus simple à définir et plus facile à défendre. Dans (Olbrich et Achermann, 2005), $d(t)$ est l'amplitude d'un oscillateur dont la valeur se situe par rapport au cercle unitaire dans le plan complexe. Leurs seuils universels $\tau_1(t) = 0.95$ (utilisé pour la détection) et $\tau_2(t) = 0.90$ (utilisé pour définir le début et la fin d'un évènement) s'expliquent directement en termes d'amortissement d'un oscillateur. Dans (Babadi et al., 2012), $d(t)$ est une probabilité *a posteriori* de la présence d'un fuseau; le choix de $\tau(t) = 50\%$ signifie qu'on franchit le seuil de la chance.

2.2.3 Régularisation

L'opération de seuillage fournit un ensemble $\tilde{\mathbf{X}}$ d'évènements $\tilde{\mathbf{x}}_n$ qui sont potentiellement des fuseaux (voir ANNEXE I pour le formalisme sur les évènements). Le symbole \sim signifie que les évènements ainsi créés par le seuillage de $d(t)$ par $\tau(t)$ peuvent être des faux positifs (FP), i.e. des évènements détectés qui ne sont pas des fuseaux. L'opération de régularisation $\mathcal{R}: \tilde{\mathbf{X}} \rightarrow \mathbf{X}$ à pour but d'éliminer le plus de FP sans éliminer de vrais positifs (VP), i.e. des évènements détectés qui sont vraiment des fuseaux. On cherche donc à améliorer la spécificité sans réduire la sensibilité. Pour ce faire, on doit définir des caractéristiques supplémentaires qui permettent de discerner les VP des FP.

A priori, l'opération de seuillage ne fournit que les caractéristiques de position $\tilde{\mathbf{x}}^{\text{début}}$ et $\tilde{\mathbf{x}}^{\text{fin}}$. Une caractéristique qui est utilisée pour la régularisation est la durée, définie par $\tilde{\mathbf{x}}^{\text{durée}} = \tilde{\mathbf{x}}^{\text{fin}} - \tilde{\mathbf{x}}^{\text{début}}$ (mesuré en secondes). Un évènement trop long ou trop court peut ainsi être considéré comme FP et rejeté (voir Figure 2.1, C, la partie grisée de \mathbf{x}_2 serait rejetée). L'intervalle des valeurs de durée est variable dans la littérature : $0.5 \text{ sec} < \tilde{\mathbf{x}}^{\text{durée}}$ dans (Babadi et al., 2012; Bodizs et al., 2009; Devuyst et al., 2006; Schabus et al., 2007), $0.3 \text{ sec} < \tilde{\mathbf{x}}^{\text{durée}} < 2 \text{ sec}$ (Schabus et al., 2006), $0.4 \text{ sec} < \tilde{\mathbf{x}}^{\text{durée}} < 1.3 \text{ sec}$ dans (Molle et al., 2002), $0.6 \text{ sec} < \tilde{\mathbf{x}}^{\text{durée}}$ dans (Held et al., 2004) et $3f^{-1} < \tilde{\mathbf{x}}^{\text{durée}}$ dans (Caplan et al., 2001; Whitten et al., 2011), où f est la fréquence de l'ondelette (s^{-1}). La raison d'une telle variabilité

dans la définition de la durée peut s'expliquer par l'interdépendance entre les fonctions $d(\mathbf{t})$ et $\tau(\mathbf{t})$, et la distribution en durée des évènements obtenus; en effet, plus $\tau(\mathbf{t})$ est élevée, plus les durées seront petites. Les limites optimales dépendent donc du choix de $d(\mathbf{t})$ et $\tau(\mathbf{t})$.

Ce type de discernement considère que la fonction de détection $d(\mathbf{t})$ est assez régulière de sorte que chaque évènement $\tilde{\mathbf{x}}_n$ est distinct des autres; en d'autres termes, l'évènement $\tilde{\mathbf{x}}_n$ ne fait pas partie de l'évènement $\tilde{\mathbf{x}}_{n-1}$ ni de l'évènement $\tilde{\mathbf{x}}_{n+1}$. Cette proposition peut ne pas être vraie si $d(\mathbf{t})$ est bruitée ou si l'amplitude d'un même évènement comporte une modulation; ainsi, l'activité d'un même évènement peut franchir le seuil plus d'une fois. Une solution est de grouper les évènements qui se suivent à un court intervalle, définit comme $\tilde{x}_n^{\text{intervalle}} = \tilde{x}_n^{\text{début}} - \tilde{x}_{n-1}^{\text{fin}}$. Ainsi, pour prendre exemple sur la Figure 2.1 C (où la partie grisée de \mathbf{x}_2 serait conservée), $\{\tilde{\mathbf{x}}_2, \tilde{\mathbf{x}}_3\} \longrightarrow \mathbf{x}_2 \Leftrightarrow \tilde{x}_3^{\text{intervalle}} < T_{\text{intervalle}}$, où $T_{\text{intervalle}}$ est une constante de temps. Dans ce cas, l'opération consistant à grouper deux évènements serait de redéfinir $x_n^{\text{début}} = \tilde{x}_i^{\text{début}}$ et $x_n^{\text{fin}} = \tilde{x}_{i+1}^{\text{fin}}$ (dans le cas des caractéristiques de position). Les travaux qui utilisent cette approches sont ceux de (Held et al., 2004) avec $T_{\text{intervalle}}$ valant 0.4sec et 0.5sec, (Causa et al., 2010) avec $T_{\text{intervalle}}$ valant 0.2sec et 0.25sec, (Ventouras et al., 2005) avec $T_{\text{intervalle}}$ valant 0.3sec. Dans (Babadi et al., 2012), ayant une fonction $d(\mathbf{t})$ initialement irrégulière, un filtre intégrateur triangulaire de longueur $T_{\text{intervalle}} = 0.5\text{sec}$ est utilisé pour adoucir $d(\mathbf{t})$ et, après l'opération de seuillage, un regroupement est effectué avec $T_{\text{intervalle}} = 0.5\text{sec}$. Encore une fois, la valeur optimale pour $T_{\text{intervalle}}$ dépend de la définition de $d(\mathbf{t})$ et $\tau(\mathbf{t})$.

Outre les caractéristiques temporelles des évènements, des caractéristiques spectrales sont aussi extraites pour rejeter de potentiels FP. (Huupponen et al., 2000a) utilisent deux quantités issues de la FFT calculée sur des fenêtres d'une seconde: un indicateur de sommeil (IS), correspondant à la fréquence moyenne dans la bande de 0.8Hz à 13Hz, et un indicateur d'artefact musculaire (EMG), correspondant au rapport de la moyenne du signal dans la bande de 20Hz à 40Hz sur la moyenne du signal dans la bande de 1.5Hz à 12.5Hz. Ainsi, un évènement est gardé si $IS < 6\text{Hz}$ et $EMG < 0.4$. Dans (Devuyst et al., 2006), une FFT est

calculée sur 500ms ; un évènement est gardé si le maximum du spectre dans la bande 7Hz-20Hz se situe dans la bande 11.5Hz-15Hz. Dans le thème de rapport d'énergie spectrale, on trouve aussi (Huupponen et al., 2007) qui définissent un index comme étant le rapport entre le maximum dans la bande 10.5Hz-16Hz et la moyenne dans les bandes 4Hz-10Hz et 20Hz-40Hz ; une valeur supérieure à 4.5 suggère la présence d'un fuseau. De manière similaire, (Devuyst et al., 2011) définissent un index correspondant au rapport de la puissance dans la bande 11Hz-15Hz sur celle de la bande 0.5Hz-40Hz ; les détections ayant un index < 0.22 sont rejetées.

2.3 Les détecteurs à classification paramétrique

Dans ce type de détecteur, $s(t) \xrightarrow{W} \tilde{\mathbf{X}}$ segmente le signal EEG $s(t)$ et transforme chaque segment en un vecteur d'attributs $\tilde{\mathbf{x}}_n$ correspondant à un évènement, ou fuseau *potentiel*, dont l'ensemble $\{\tilde{\mathbf{x}}_n\}$ forme la matrice $\tilde{\mathbf{X}}$ (Figure 2.2, B). L'étape de classification suit et peut être de deux types. Un classificateur par apprentissage (ou supervisé) *apprend*, via une base de données d'entraînement, à classer un évènement $\tilde{\mathbf{x}}_n$ comme étant un fuseau (\mathbf{x}_i) ou un non-fuseau (\mathbf{y}_j) (Figure 2.2, C, I). L'autre approche de classification, par partitionnement (ou par regroupement), regroupe entre eux les évènements qui se *ressemblent* pour former une partition homogène selon un critère donné (des groupes, des classes, des *clusters*). Au cours de l'apprentissage, certaines de ces classes regroupent des évènements fuseaux ($\mathbf{x}_i, \mathbf{x}_k$) tandis que les autres regroupent des évènements non-fuseaux ($\mathbf{y}_j, \mathbf{y}_l$) (Figure 2.2, C, II).

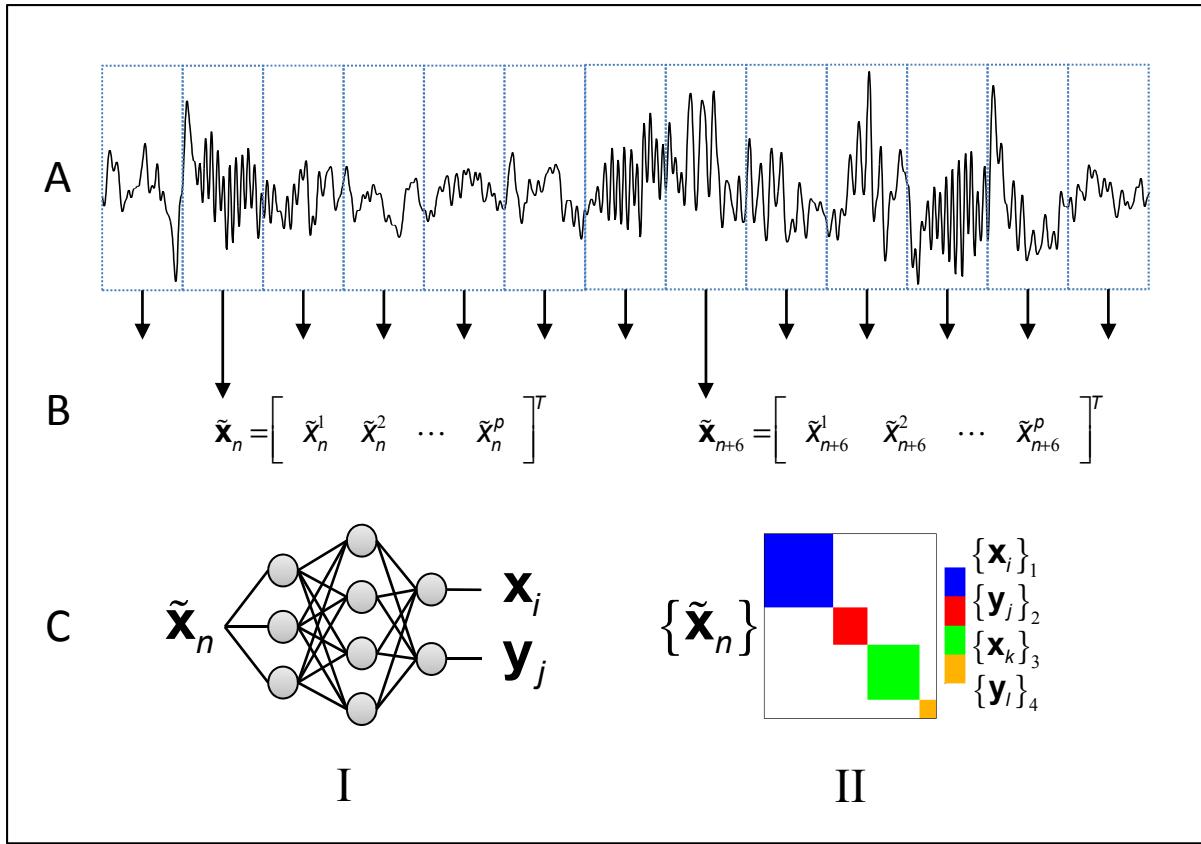


Figure 2.2 Schéma de détection par classification paramétrique

A: Segmentation du signal EEG. B: Paramétrisation de chaque segment. C: Classification I) supervisée (illustré par un réseau de neurones artificiels) ou II) non-supervisée (illustré par une matrice de distance partitionnée)

En général, tout problème de classification peut se décomposer en deux étapes : l'extraction des caractéristiques (ou paramétrisation) et la classification en soi (qui doit être validée avec un ensemble de données test). Les prochaines sections rapportent les approches proposées dans la littérature de détection de fuseaux pour ces deux étapes respectivement mais avant, on rapporte les méthodes de segmentation des données qui permettent de créer des *événements*.

2.3.1 Segmentation

Le vecteur de caractéristiques $\tilde{\mathbf{x}}_n$ doit correspondre à un évènement, i.e. un intervalle de temps qui supporte une activité $s(\mathbf{t})$, et qui peut potentiellement être la manifestation d'un fuseau. La première étape avant d'aborder le problème d'extraction de ces caractéristiques est de définir une telle partition de \mathbf{t} .

La solution la plus simple est une segmentation régulière de longueur $T_{segment}$ (en secondes), avec un recouvrement r (*overlap*) entre 0% et 100% (un recouvrement $r = 0\%$ est illustré à la Figure 2.2 A). Cette partition crée ainsi N évènements $\tilde{\mathbf{x}}_n$ de durée $T_{segment}$ qui se chevauchent sur une durée $rT_{segment}$. En utilisant la notation présentée à l'ANNEXE I, on a $\tilde{x}_n^{durée} = T_{segment}$ et $\tilde{x}_n^{fin} - \tilde{x}_{n+1}^{début} = rT_{segment}$. Un recouvrement de 0% signifie que les segments se suivent sans se recouvrir. Un recouvrement de 100% correspond à $\tilde{x}_{n+1}^{début} - \tilde{x}_n^{début} = \Delta t$ (pas d'échantillonnage). Cette approche est utilisée dans (Huupponen et al., 2000b) avec $T_{segment} = 1\text{s}$ et 0% de recouvrement, dans (Gorur et al., 2003; Gorur et al., 2002) avec $T_{segment} = 0.5\text{s}$ et un recouvrement non spécifié (mais plus grand que 0%), dans (Acir et Guzelis, 2004) avec $T_{segment} = 3\text{s}$ et un recouvrement de 100% et dans (Sinha, 2008) avec $T_{segment} = 2\text{s}$ et un recouvrement non spécifié. On note que $T_{segment}$ est choisi en respectant les durées admises pour les fuseaux : grossièrement, entre 0.5sec et 3sec. Le recouvrement est plus arbitraire ; son choix est un compromis entre résolution temporelle et quantité d'évènements à traiter.

2.3.2 Extraction des caractéristiques

L'opération de création d'évènements fournit des vecteurs $\tilde{\mathbf{x}}_n$ de caractéristiques contenant uniquement des coordonnées de position $\tilde{x}_n^{début}$ et \tilde{x}_n^{fin} , qui ne sont généralement pas les caractéristiques qui servent à la classification. Il faut donc transformer (ou paramétriser) l'activité supportée entre ces positions, $s(\tilde{x}_n^{début} \leq \mathbf{t} \leq \tilde{x}_n^{fin})$, en caractéristiques (ou paramètres) permettant ensuite une classification qui discernera les fuseaux des non-fuseaux. Les

caractéristiques qui seront retenues pour la classification formeront le vecteur $\tilde{\mathbf{x}}_n^*$ ($\tilde{\mathbf{x}}_n^*$ est un sous-ensemble des caractéristiques de $\tilde{\mathbf{x}}_n$).

La solution la plus simple est d'utiliser, comme caractéristique modélisant l'évènement, directement l'activité *brute*, sans transformation : $\tilde{\mathbf{x}}_n^* = \mathbf{s}(\tilde{x}_n^{\text{début}} \leq \mathbf{t} \leq \tilde{x}_n^{\text{fin}})$. Dans, (Ventouras et al., 2005), ce sont 500ms du signal filtré dans la bande 10.5Hz-16Hz qui sont utilisées comme $\tilde{\mathbf{x}}_n^*$. Cette approche a comme avantage de garder toute l'information contenue dans le signal, mais ce peut également être un inconvénient: le bruit peut avoir un impact important et la dimension n'est pas réduite (autant de caractéristiques que d'échantillons temporels). Cette approche manque donc de spécificité.

L'approche paramétrée est plus utilisée, car elle permet de compacter l'information contenue dans l'activité de l'évènement. Les caractéristiques correspondent à une réduction dimensionnelle et plus proche de la complexité du problème. Dans le domaine temporel, un paramétrage par modèle autorégressif (AR) est utilisé : (Gorur et al., 2003) avec 16 coefficients, (Acir et Guzelis, 2004) avec 15 coefficients et (Olbrich et Achermann, 2005) avec 8 coefficients. Le choix du nombre de coefficients est un compromis entre la justesse de modélisation (biais du modèle) et la complexité (variance du bruit).

Des caractéristiques fréquentielles sont aussi utilisées dans la littérature. Une solution simple est d'utiliser les coefficients de Fourier calculés par FFT sur des courts segments de données *fenêtrées*, i.e. pondérée de sorte que les extrémités sont adoucies pour atténuer les effets de bord et améliorer la résolution fréquentielle. Cette méthode est connue sous le nom de *Short Time Fourier Transform* (STFT). La STFT est utilisée dans (Gorur et al., 2002) sur des segments de 500ms avec une fenêtre de Hamming et 32 coefficients couvrant la bande 2Hz-64Hz. Les travaux de (Huupponen et al., 2000b) utilisent aussi la STFT (segments de 1s et fenêtre de Saramaki), mais compressent davantage l'information en seulement quatre caractéristiques $\tilde{\mathbf{x}}_n^* = [\tilde{x}_n^1 \ \tilde{x}_n^2 \ \tilde{x}_n^3 \ \tilde{x}_n^4]^T$: $\tilde{x}_n^1 = A_\sigma / A_\theta$ est le rapport entre une estimation de l'amplitude maximale dans la bande sigma (A_σ) et l'amplitude moyenne dans la bande thêta

(A_θ), $\tilde{X}_n^2 = A_\sigma / A_\alpha$ est le rapport entre A_σ et l'amplitude maximale dans la bande alpha (A_α), $\tilde{X}_n^3 = A_\sigma / A_\gamma$ est le rapport entre A_σ et l'amplitude moyenne dans la bande gamma (A_γ), et finalement \tilde{X}_n^4 est la fréquence moyenne dans la bande 8Hz-13Hz.

Il est aussi possible de caractériser un évènement à la fois dans le domaine temporel et dans le domaine fréquentiel ; on regroupe ces méthodes sous le terme d'analyse temps-fréquence. Dans la littérature de détection de fuseaux, on retrouve principalement la famille des Transformées en ondelettes et le *Matching Pursuit* (MP). La Transformée en ondelettes discrète de Daubechies (*Discrete Wavelet Transform*, DWT) est utilisée dans (Sinha, 2008) pour extraire 64 coefficients temps-fréquence couvrant la bande 0.5Hz-32Hz sur des segments de 2s. Dans (Ahmed, Redissi et Tafreshi, 2009), un seul attribut temps-fréquence est extrait de segments de 1.28s à l'aide des paquets d'ondelettes (*Wavelet Packet Transform*, WPT) : le rapport entre l'énergie des coefficients temps-fréquence des bandes 9Hz-12Hz et 1Hz-4Hz.

L'analyse par MP offre une représentation sous une forme pratiquement équivalente aux ondelettes et Fourier : le signal est une somme pondérée de fonctions élémentaires, ou *atomes* de signal. Ces atomes sont les ondelettes dans la DWT et les harmoniques complexes dans la FFT. Cependant, le MP est différent dans sa façon de construire cette représentation : plutôt que de projeter le signal sur une base prédéfinie dont la représentation temps-fréquence est rigide (DWT et FFT), le MP choisit itérativement l'atome expliquant le plus d'énergie dans le *résidu* de signal à chaque itération. De plus, les atomes font partie d'un large *dictionary* redondant et chaque atome peut avoir une position et une extension arbitraire dans le plan temps-fréquence, offrant une représentation temps-fréquence adaptée au signal. Le dictionnaire peut inclure la famille des ondelettes et des harmoniques complexes. Une famille utilisée pour la détection des fuseaux est celle des atomes de Gabor (Durka et al., 2005; Malinowska et al., 2007; Schonwald et al., 2006; Zygierek et al., 1999), correspondant à une harmonique pondérée par une enveloppe, à la manière de la

STFT. Les atomes de Gabor peuvent avoir une combinaison arbitraire de fréquence d'oscillation et de durée (caractéristique temps-fréquence).

La particularité du MP dans le contexte de détection d'évènement est que le dictionnaire correspond à une base d'évènements caractérisés *a priori*. Ainsi, la représentation de $s(\mathbf{t})$ par MP fournit directement des vecteurs d'attributs $\tilde{\mathbf{X}}_n$. Dans le cas des atomes de Gabor, ce sont la fréquence, la durée et l'énergie (correspondant au coefficient de projection).

2.3.3 Classification

L'étape de classification consiste à classer un vecteur d'attributs $\tilde{\mathbf{X}}_n^*$ comme étant un fuseau (\mathbf{x}_i) ou non ($\bar{\mathbf{x}}_j$). On a vu dans la section 2.2.3, portant sur la régularisation du détecteur de type 1, un exemple d'une telle classification : l'opération de seuillage génère des fuseaux potentiels $\tilde{\mathbf{X}}_n$ auxquels on ajoute des caractéristiques (durée, rapport spectral, etc.) permettant de trancher en faveur d'un fuseau ou non. Dans le cas du détecteur de type 2, les évènements, ou fuseaux potentiels, arrivent directement sous une forme paramétrée par plusieurs caractéristiques de même ou différente nature, comme on la vu à la section précédente. La classification est le problème principal dans ce type de détecteur.

La première approche de classification, qui est majoritairement rencontrée dans la littérature, est d'*entraîner* un système à reconnaître un fuseau (\mathbf{x}_i) à partir d'un vecteur d'attributs $\tilde{\mathbf{X}}_n^*$.

Si $\tilde{\mathbf{X}}_n^*$ est un vecteur contenant N_p caractéristiques, on peut le représenter comme un point dans un espace abstrait Φ à N_p dimensions. L'apprentissage consiste à tracer une frontière dans cet espace de sorte qu'un sous-espace Φ^1 représente l'ensemble de points qui correspondent à ce qu'on considère comme fuseau. Le complément de ce sous-espace, Φ^0 , correspond à ce qu'on considère comme non-fuseau. Un évènement fuseau potentiel $\tilde{\mathbf{X}}_n^*$ se situant dans le sous-espace Φ^1 sera considéré comme fuseau.

Dans le cas où les caractéristiques de $\tilde{\mathbf{x}}_n^*$ correspondent à des quantités physiques dont les plages de valeurs possibles pour un fuseau sont connues, une base de données d'entraînement n'est pas nécessaire, car Φ^1 est connu et peut être explicitement exprimé. Cela consiste donc en une forme simple d'entraînement du système. C'est le cas du MP où $\tilde{\mathbf{x}}_n^* = [\tilde{x}_n^{\text{durée}} \ \tilde{x}_n^{\text{fréquence}} \ \tilde{x}_n^{\text{amplitude}}]^T$ consiste en la durée, la fréquence d'oscillation et l'énergie (ou l'amplitude) (Durka et al., 2005; Malinowska et al., 2007; Schonwald et al., 2006; Zygierek et al., 1999). Puisque q'on connaît ces trois quantités pour les fuseaux, la partition $\Phi \rightarrow \Phi^1 \cup \Phi^0$ est directement connue. Φ^1 est ainsi défini dans la littérature pour l'analyse MP : moyennant quelques variations d'un groupe à l'autre, $0.5s \leq \tilde{x}_n^{\text{durée}} \leq 2s$, $10\text{Hz} \leq \tilde{x}_n^{\text{fréquence}} \leq 16\text{Hz}$ et $15\mu\text{V} \leq \tilde{x}_n^{\text{amplitude}}$.

Dans le cas où les caractéristiques de $\tilde{\mathbf{x}}_n^*$ correspondent à des quantités formant un espace Φ dont la structure n'est pas connue *a priori*, une solution est d'estimer la frontière séparant Φ^1 et Φ^0 en entraînant un système à partir d'une base de données d'*entraînement* (qui est différente de la base de données de *validation* qui sert à valider la performance du système entraîné). Cette méthode consiste en une classification supervisée (voir Figure 2.2, C, I). Les réseaux de neurones artificiels (*Artificial Neural Network*, ANN) sont de tels systèmes qui sont utilisés dans la détection de fuseaux. Le plus simple d'entre eux est le perceptron, utilisé dans (Acir et Guzelis, 2004) comme pré-classification, permettant de réduire considérablement le nombre de fuseaux potentiels avant une post-classification plus complexe. Avec ce système, on considère que Φ^1 et Φ^0 sont linéairement séparables.

Une version évoluée du perceptron est le perceptron multicouche (*Multi-Layer Perceptron*, MLP), utilisé dans (Acir et Guzelis, 2004; Gorur et al., 2003; Gorur et al., 2002; Ventouras et al., 2005). Dans ce système, la frontière séparant Φ^1 et Φ^0 n'est pas nécessairement linéaire et on compte, en général, trois *couches* de neurones artificiels : la première (la couche d'entrée), dont le nombre de neurones $N_{\text{entrée}}^{\text{ANN}}$ correspond au nombre de caractéristiques de $\tilde{\mathbf{x}}_n^*$; la deuxième (la couche cachée), dont le nombre de neurones $N_{\text{cachée}}^{\text{ANN}}$ fixe la complexité du

système; la troisième (la couche de sortie), dont le nombre de neurones $N_{\text{sortie}}^{\text{ANN}}$ correspond au nombre de classes d'intérêt. L'architecture $N_{\text{entrée}}^{\text{ANN}} - N_{\text{cachée}}^{\text{ANN}} - N_{\text{sortie}}^{\text{ANN}}$ utilisée dans les travaux cités est respectivement 32-60-1, 17-30-1, 15-14-1 et 64-30-2.

Dans (Huupponen et al., 2000b), c'est un MLP autoassociatif 4-3-4 qui est utilisé. Dans ce cas, $N_{\text{entrée}}^{\text{ANN}} = N_{\text{sortie}}^{\text{ANN}}$ et $N_{\text{entrée}}^{\text{ANN}} > N_{\text{cachée}}^{\text{ANN}}$; le système est considéré entraîné quand il est en mesure de bien répliquer en sortie le vecteur d'entrée $\tilde{\mathbf{x}}_n^*$. Pour un tel système, la base de données d'entraînement peut contenir uniquement des exemplaires de points dans Φ^1 (des fuseaux), contrairement aux autres formes de perceptron qui nécessitent à la fois des exemplaires dans Φ^1 et dans Φ^0 .

Les machines à vecteurs de support (*Support Vector Machines*, SVM) sont aussi utilisées dans la littérature (Acir et Guzelis, 2004; Gorur et al., 2003; Gorur et al., 2002). Ces systèmes construisent un plan dans Φ qui sépare Φ^1 et Φ^0 en maximisant une marge autour de ce plan. Si le problème ne se résout pas linéairement (un plan), il est possible de projeter non-linéairement le problème dans un espace où la résolution est linéaire. Au final, la classification est uniquement fonction des vecteurs de support, le sous-ensemble des exemplaires d'entraînement qui se situent sur les marges du plan.

2.4 Approches multicanaux

Les détecteurs de fuseaux présentés précédemment fonctionnent sur un signal $s(\mathbf{t})$ unique (univarié), sur un capteur EEG particulier. Certains des travaux qui explorent l'aspect spatial (ou topographique) de la détection automatique des fuseaux appliquent, indépendamment sur chaque capteur EEG, un algorithme de détection développé pour un signal $s(\mathbf{t})$ univarié (Huupponen et al., 2007; Huupponen et al., 2005; Zygierekiewicz et al., 1999). Ainsi, l'algorithme fournit les marqueurs des événements fuseaux avec au moins les caractéristiques spatio-temporelles $\mathbf{x}_n = [x_n^{\text{capteur}} \ x_n^{\text{début}} \ x_n^{\text{fin}}]^T$, soit le capteur EEG sur lequel il est détecté et les instants de début et de fin.

Dépendamment de l'application, ces évènements peuvent être considérés comme uniques, comme dans (Zygierewicz et al., 1999), ou être regroupés selon leur recouvrement temporel ; dans (Huupponen et al., 2007), un évènement est considéré comme fuseau s'il est bilatéral, i.e. si les critères de détection sont rencontrés simultanément sur les électrodes des hémisphères gauche et droit. Dans un travail ultérieur (Huupponen et al., 2008), les fuseaux sont davantage caractérisés par leur *diffusion*, i.e. si les critères de détection sont rencontrés sur les capteurs frontaux et centraux simultanément.

Dans ces approches de détection, l'aspect topographique est considéré *a posteriori*. Parmi les méthodes de détection intégrant l'aspect topographique *a priori*, on trouve le travail de (Durka et al., 2005) qui propose une approche MP multicanaux; la décomposition du signal par MP fournit les atomes (de Gabor) qui expliquent le plus d'énergie sur tous les canaux, plutôt que de décomposer les canaux indépendamment.

La décomposition en composantes indépendantes (*Independent Components Analysis*, ICA) est une technique permettant de transformer un signal multivarié (dans le cas de l'EEG, chaque variable correspond à un capteur) en un autre signal multivarié donc chaque variable est statistiquement indépendante des autres. On peut donc considérer ces composantes comme étant des topographies spatiales dont les signaux temporels sont statistiquement indépendants les uns des autres. Dans (Ventouras et al., 2007; Ventouras et al., 2010), cette méthode est appliquée sur des segments de signal de fuseaux détectés visuellement. Une topographie parmi celles des composantes indépendantes est ensuite manuellement sélectionnée pour servir à reconstruire les sources cérébrales par LORETA (*Low Resolution Brain Electromagnetic Tomography*). Dans une approche plus axée sur la détection des fuseaux, les travaux de (Barros et al., 2000; Rosipal, Dorffner et Trenker, 1998) proposent l'ICA pour fournir un seul signal univarié, représentant l'activité d'une topographie supposée spécifique aux fuseaux, à partir d'un signal multivarié. La façon dont les composantes indépendantes d'intérêt sont sélectionnées reste toutefois par inspection visuelle.

2.5 Évaluation de la performance

Un détecteur automatique de fuseaux fournit un ensemble $\mathbf{X} = \{\mathbf{x}_n\}$ d'évènements qui ont répondu aux critères de détection. L'évaluation de sa performance consiste à mesurer sa concordance avec un autre ensemble $\mathbf{U} = \{\mathbf{u}_n\}$ d'évènements qui sont considérés comme *d'absolument vrais* fuseaux. On appelle cet ensemble "*gold standard*". Il est usage de prendre comme "*gold standard*" des évènements créés manuellement par un *expert*, i.e. un technicien dont la profession est de lire et interpréter, par inspection visuelle, des tracés EEG. Pour marquer un fuseau sur un tracé EEG, l'expert se base sur les règles de R&K (Rechtschaffen et Kales, 1968) et de l'AASM (Iber et al., 2007). La détection visuelle d'un fuseau consiste à définir un instant de début $u_n^{\text{début}}$ et un instant de fin u_n^{fin} pour former l'évènement $\mathbf{u}_n = [u_n^{\text{début}} \ u_n^{\text{fin}}]^T$.

La concordance entre \mathbf{X} et \mathbf{U} se mesure en termes de vrais positifs (VP), faux positifs (FP), vrais négatifs (VN) et faux négatifs (FN). En termes généraux, un VP est un évènement marqué par l'expert et le détecteur, un FP est marqué seulement par le détecteur, un FN est marqué seulement par l'expert et un VN n'est marqué par aucun des deux. La concordance est définie dans le domaine temporel \mathbf{t} : deux évènements \mathbf{x}_i et \mathbf{u}_j concordent si $x_i^{\text{début}} < u_j^{\text{fin}}$ et $x_i^{\text{fin}} > u_j^{\text{début}}$.

Pour vérifier la performance d'un algorithme de détection, on s'intéresse principalement à 2 propriétés : sa *sensibilité* et sa *spécificité*. Grossièrement, la sensibilité est l'aptitude de marquer un fuseau là où il y a véritablement un fuseau et la spécificité est l'aptitude de ne pas marquer de fuseau là où il n'y a véritablement pas de fuseau. On trouve dans la littérature diverses définitions de ces deux propriétés et parfois des noms différents pour des définitions équivalentes. Cette confusion de terminologie rend les comparaisons directes difficiles (Devuyst et al., 2011). Dans le présent ouvrage, on utilise donc la terminologie présentée dans le travail de Devuyst. Le Tableau 2.1 regroupe les différentes mesures de performance qui seront utilisées dans ce travail. Dans ce tableau, N_{VP} , N_{FP} , N_{VN} et N_{FN} représentent

respectivement le nombre de VP, FP, VN et FN. On considère que $N_U \approx N_{VP} + N_{FN}$, où N_U est le nombre d'évènements marqués par l'expert, et que $N_X \approx N_{FP} + N_{VP}$, où N_X est le nombre d'évènements détectés par le détecteur. T correspond à la durée total des données, en secondes.

Tableau 2.1 Définitions des mesures de performance

Mesure	Formule	Numéro d'équation
Sensibilité (Se)	$Se = \frac{N_{VP}}{N_{FN} + N_{VP}} \approx \frac{N_{VP}}{N_U}$	(2.1)
Spécificité (Sp)	$Sp = \frac{N_{VN}}{N_{FP} + N_{VN}}$	(2.2)
<i>False Positive rate</i> (FPr)	$FPr = \frac{N_{FP}}{N_{FP} + N_{VN}} = 1 - Sp$	(2.3)
<i>False Positive amount</i> (FPa)	$FPa = \frac{N_{FP}}{N_{FP} + N_{VP}} = 1 - PPV \approx \frac{N_{FP}}{N_X}$	(2.4)
<i>False Positive proportion</i> (FPp)	$FPp = \frac{N_{FP}}{N_{FN} + N_{VP}} \approx \frac{N_{FP}}{N_U}$	(2.5)
<i>False Alarm rate</i> (FAr)	$FAr = \frac{N_{FP}}{T}$	(2.6)

La définition formelle de la sensibilité Se est stable dans la littérature, mais les noms varient:

- *True Positive Rate* (TPR) (Huupponen et al., 2007; Huupponen et al., 2005; Huupponen et al., 2000a; Huupponen et al., 2000b),
- *Accuracy* (Ahmed, Redissi et Tafreshi, 2009; Sinha, 2008),
- *Agreement Rate* (Held et al., 2004; Sinha, 2008; Zygierekiewicz et al., 1999),
- *Hit Rate* (Babadi et al., 2012),
- *Performance* (Gorur et al., 2003; Gorur et al., 2002).

En addition (ou substitution) de la spécificité Sp définie à l'équation 2.2, plusieurs mesures ont été définies pour estimer un *taux* de FP. Le taux de FP (*False Positive rate*, FPr), défini à l'équation 2.3, est simplement l'inverse additif de Sp . La *False Positive amount* (FPa) est une alternative proposée par Devuyst et est définie à l'équation 2.4. La FPa peut aussi être exprimée en termes de la valeur prédictive positive (*Positive Predictive Value*, PPV) définie comme $N_{VP}/(N_{FP}+N_{VP})$. Cette mesure est utilisée sous le nom *False Positive Rate* dans (Bodizs et al., 2009; Causa et al., 2010; Huupponen et al., 2007; Ventouras et al., 2005) et *False Discovery Rate* dans (Babadi et al., 2012). La mesure complémentaire $PPV = 1-FPa$ est utilisée sous le nom *System Precision* dans (Held et al., 2004).

Devuyst propose aussi une proportion de FP (*False Positive proportion*, FPp), qui ne trouve aucun équivalent exact dans la littérature et qui est définie à l'équation 2.5. Enfin, on peut mentionner une autre estimation d'un taux de FP, nommée *False Alarm rate* (FAr), proposée dans (Babadi et al., 2012) et définie à l'équation 2.6. Dans ce cas, la seule variable à comptabiliser est N_{FP} et le résultat est en unité physique de l'inverse du temps (s^{-1}). Cependant, cette mesure est une moyenne et considère que les FP sont uniformément distribués dans le temps.

2.6 Objectifs du présent travail

La plus grande problématique dans le domaine de la détection automatique de fuseaux est l'absence d'une définition spécifique de ce qu'est un fuseau. Malgré une définition assez universelle en fréquence (entre $11\text{Hz} \pm 1\text{Hz}$ et $15\text{Hz} \pm 1\text{Hz}$) et en durée (entre $0.5\text{sec} \pm 0.2\text{sec}$ et $2\text{sec} \pm 1\text{sec}$), les caractéristiques utilisées pour la détection (par exemple, dérivées de l'amplitude pour les détecteurs de type 1) n'ont pas de bornes générales et spécifiques dû, entre autres, à la variabilité inter-sujet.

Ce manque de spécificité dans la définition même des fuseaux résulte en des détecteurs ayant des taux de faux positifs (mesurés par FPr , FPa , FAr , FPp , etc.) relativement élevés pour obtenir une sensibilité acceptable. Pour ajouter au problème, le *gold standard*, i.e. le marquage des fuseaux par un expert, a une variabilité intrinsèque relativement élevée (Devuyst et al., 2011; Huupponen et al., 2007; Ventouras et al., 2005). Ceci rend délicat l'ajustement des paramètres d'un détecteur automatique pour obtenir un compromis entre sensibilité et spécificité ; la bonne performance d'un détecteur mesuré par un expert peu du coup être mauvaise pour un autre.

Le but du présent travail est d'ajouter une étape de classification non-supervisée à un algorithme sensible à des fins de spécificité. Pour ce faire, le premier objectif est de développer, en guise de pré-détection, un algorithme très sensible ($Se \geq 90\%$) et potentiellement peu spécifique, basé sur des caractéristiques validées par la littérature, soit l'amplitude et l'index de rapport spectral *sigma* (Huupponen et al., 2007). Le deuxième objectif est de développer, en guise de post-détection, un algorithme de classification hiérarchique non-supervisé basé sur deux caractéristiques : l'une spatiale (la position sur l'axe antéro-postérieur du scalp) et l'autre fréquentielle (la fréquence d'oscillation). La sélection supervisée d'un sous-ensemble de classes a ainsi comme but de rejeter les événements qui *ne ressemblent pas* à des événements définis par un expert (selon les critères spatio-fréquentiels), augmentant la spécificité tout en gardant la sensibilité élevée.

CHAPITRE 3

MÉTHODOLOGIE

Ce chapitre décrit les étapes qui conduisent à la conception d'un algorithme de détection de fuseaux: 1) une phase de « détection sensible » basée sur des caractéristiques établies dans la littérature et 2) une phase de « détection spécifique » consistant en une classification des événements basée sur des caractéristiques spatiale et fréquentielle.

On commence par décrire un montage de détection spécifique aux fuseaux qui permet de représenter l'activité de plusieurs capteurs en un seul signal sur lequel la détection sera effectuée. On définit ensuite un outil d'analyse qui sert à filtrer le signal pour cibler l'activité de fuseau : la transformée en ondelettes continue (CWT). Le signal filtré est ensuite transformé en une fonction de détection servant à segmenter l'enregistrement en événements de durée finie. Pour chacun de ces événements, on extrait finalement des caractéristiques sur lesquelles la sélection est basée.

Cette sélection se fait en deux étapes. Dans la première, on considère deux caractéristiques à maximiser : l'amplitude et un rapport spectral. Des seuils sont calculés en fixant une *p-value* sur une hypothèse nulle (« l'évènement n'est pas un fuseau »). Dans la seconde étape de sélection, on effectue une classification hiérarchique sur deux autres caractéristiques : la fréquence d'oscillation et la position sur l'axe médian du scalp. La classe sélectionnée sera celle dont les membres ressemblent le plus à des événements marqués par un expert. On termine en définissant les mesures de performance de l'algorithme.

3.1 Montage de détection

Dans cette section, on considère une *topographie*, ou *montage*, sous la forme d'un vecteur $\mathbf{m} = [m_{1:N_c}]^T$ de N_c éléments, qui regroupe l'activité des électrodes qui sont impliquées dans l'activité de fuseau que l'on souhaite détecter. On sait que cette dernière se manifeste

principalement sur les électrodes frontales (F3, Fz, F4), centrales (C3, Cz, C4) et pariétales (P3, Pz, P4). Le montage de détection doit donc cibler ces électrodes en particulier.

On considère la matrice $\mathbf{S} = \begin{bmatrix} \mathbf{s}^{(1)} & \mathbf{s}^{(2)} & \dots & \mathbf{s}^{(N_c)} \end{bmatrix}^T$ générée par concaténation des vecteurs de la forme $\mathbf{s}^{(c)} = \begin{bmatrix} s_1^{(c)} & s_2^{(c)} & \dots & s_{N_t}^{(c)} \end{bmatrix}^T$ dont chaque élément $s_i^{(c)}$ représente l'activité EEG mesurée sur un capteur c à un instant i . \mathbf{S} est donc une matrice de N_c lignes par N_t colonnes, où N_c est le nombre de capteurs et N_t est le nombre d'échantillons temporels. Chaque élément du montage \mathbf{m} correspond à un *poids* qu'on attribue à chaque capteur dans le montage de sorte que le produit matriciel

$$\mathbf{s}^{(\mathbf{m})} = \mathbf{m}^T \mathbf{S} \Leftrightarrow s_i^{(\mathbf{m})} = \sum_{c=1}^{N_c} m_c s_i^{(c)} \quad (3.1)$$

représente le décours temporel $\mathbf{s}^{(\mathbf{m})}$ de cette configuration (ou mélange) de capteurs. Dans le cas où plusieurs montages sont nécessaires, on peut concaténer N_m montages \mathbf{m}_i pour former la matrice $\mathbf{M} = \begin{bmatrix} \mathbf{m}_1 & \mathbf{m}_2 & \dots & \mathbf{m}_{N_m} \end{bmatrix}$; le produit de l'équation précédente reste valide, mais cette fois le résultat $\mathbf{s}^{(\mathbf{M})} = \mathbf{M}^T \mathbf{S}$ est une matrice de dimension N_m par N_t .

Le montage de détection est défini ici comme suit : \mathbf{m} est un vecteur de N_c éléments, dont les éléments correspondant aux électrodes d'intérêt (F3, Fz, F4, C3, Cz, C4, P3, Pz, P4) sont mis à 1 et tous les autres à 0. Ainsi, on ne biaise pas la sensibilité sur chacune de ces électrodes ; le *poids* attribué à chacune est le même. On doit ensuite normaliser les valeurs des poids de sorte que les unités d'amplitudes du signal résultant de $\mathbf{s}^{(\mathbf{m})} = \mathbf{m}^T \mathbf{S}$ reflètent adéquatement celles de \mathbf{S} . On divise ainsi chaque valeur de \mathbf{m} par $\sum_c |m_c| = \|\tilde{\mathbf{m}}\|_1$, où $\|\tilde{\mathbf{m}}\|_1$ symbolise la *norme 1* d'un vecteur. Dans le cas présent, avec neuf électrodes d'intérêt, chaque poids normalisé serait 1/9. Chaque capteur contribue de façon équitable.

Le choix de cette normalisation est motivé par cet exemple : considérons le vecteur \mathbf{u} représentant la distribution de la tension sur le scalp à un instant t_i et dont toutes les valeurs sont égales à 1V. L'application de la topographie donne comme valeur $\mathbf{s}^{(m)} = \mathbf{m}^T \mathbf{u} = 1V$. Puisque l'opération est linéaire, si le scalp est ultérieurement entièrement activé à une valeur arbitraire kV , on obtient $\mathbf{s}^{(m)} = \mathbf{m}^T (k\mathbf{u}) = k(\mathbf{m}^T \mathbf{u}) = kV$.

La Figure 3.1 illustre les signaux $\mathbf{S}^{(M)}$ résultant de l'application de six montages (\mathbf{m}_1 à \mathbf{m}_6 , formant la matrice \mathbf{M}) à partir d'un segment \mathbf{S} de signaux contenant des fuseaux.

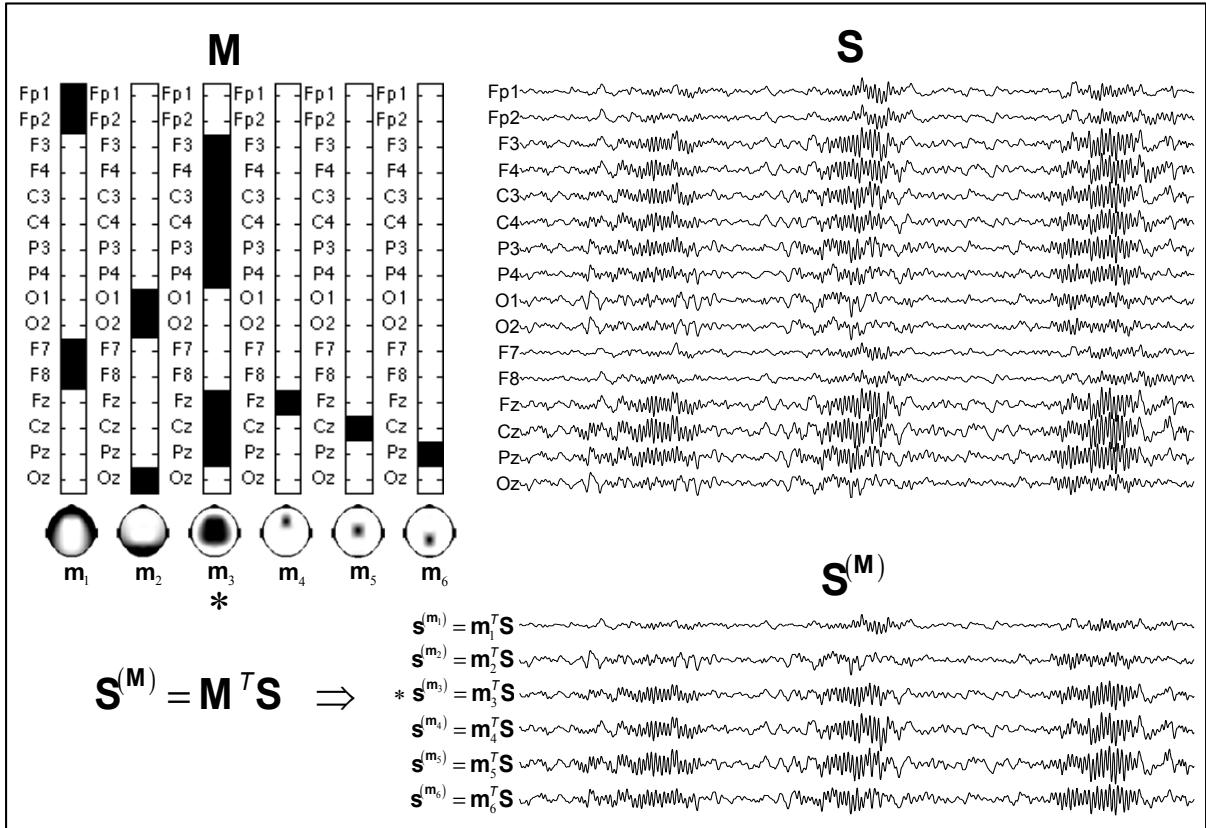


Figure 3.1 Illustration de l'utilisation de montages

\mathbf{m}_1 correspond aux électrodes frontales Fp1, Fp2, F7 et F8, \mathbf{m}_2 correspond aux électrodes occipitales O1, O2 et Oz, \mathbf{m}_3 correspond aux électrodes F3, F4, C3, C4, P3, P4, Fz, Cz et Pz,

\mathbf{m}_4 correspond uniquement à Fz, \mathbf{m}_5 correspond uniquement à Cz et \mathbf{m}_6 correspond uniquement à Pz. Plusieurs méthodes permettent de construire une topographie à partir des données, comme l'analyse en composantes indépendantes (*Independant Components Analysis*, ICA) ou l'analyse en composantes principales (*Principal Components Analysis*, PCA). Ces techniques de décomposition cherchent à maximiser une information contenu dans un signal multivarié, comme l'indépendance statistique (ICA) ou la décorrélation de la covariance (PCA). Le choix de montages fixes (non-appris des données) pour ce travail est fondé sur la connaissance *a priori* de la topographie des fuseaux. Ainsi, la spécificité spatiale (ou le poids attribué à chaque capteur) est toujours la même, indépendante du contenu et de la variabilité des données à analyser.

Le but de cette représentation est de décomposer l'activité multivariée, mesurée en plusieurs positions ponctuelles, en des mélanges de capteurs représentant l'activité sur des régions spatiales étendues, diminuant la complexité computationnelle. Le montage d'intérêt est \mathbf{m}_3 , qui regroupe l'activité des capteurs connus pour manifester l'activité de fuseaux. Les autres montages servent de référence dans ce travail pour valider les résultats obtenus sur \mathbf{m}_3 . Les montages \mathbf{m}_4 , \mathbf{m}_5 et \mathbf{m}_6 reviennent à extraire les signaux originaux sur Fz, Cz et Pz respectivement et servent de *gold standard*, car les fuseaux sont traditionnellement détectés sur ces électrodes. Pour ce qui est des montages \mathbf{m}_1 et \mathbf{m}_2 , couvrant respectivement les régions fronto-polaires et occipitales, on ne s'attend pas à obtenir de bonnes performances de détection, car elles ne sont généralement pas impliquées dans l'observation des fuseaux; ces montages servent ainsi à valider la spécificité spatiale de la méthodologie.

3.2 La transformée en ondelettes continue (CWT)

Une ondelette est une fonction $\psi(t) \in \mathbf{L}^2(\mathbb{R})$ ayant au moins les propriétés suivantes : de moyenne nulle $\int \psi(t) dt = 0$, décroissance rapide autour de l'origine ($t = 0$) et normalisée $\|\psi(t)\| = 1$ (Mallat, 1999). C'est une oscillation ayant un support temporel fini, donc qui est localisée en temps et en fréquence. Ainsi, en projetant successivement une fonction sur l'ondelette qu'on déplace dans le temps et qu'on comprime ou dilate (ce qui équivaut à un

déplacement en fréquence), on peut remplir un *plan temps-fréquence*; le résultat est la représentation temps-fréquence de la fonction.

Les ondelettes continues constituent une famille de fonctions générée par l'expression suivante:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (3.2)$$

où a est le paramètre d'échelle (ou fréquentiel) et b est le paramètre temporel. L'effet de a est de comprimer (et dilater) l'ondelette, permettant de jouer sur la fréquence d'oscillation. L'effet de b est de translater l'ondelette dans le temps. La Transformée en ondelettes continue (CWT) est définie comme suit :

$$W(a,b) \equiv \int_{-\infty}^{\infty} \psi_{a,b}^*(t) s(t) dt \quad (3.3)$$

où $W(a,b)$ représente les coefficients en ondelettes en fonction de a et b et le symbole $*$ signifie le complexe conjugué. L'ondelette $\psi(t)$ peut être vue comme un filtre passe-bande; l'opération CWT consiste donc à filtrer $s(t)$ à l'aide d'un filtre $\psi(t)$ qu'on comprime ou étire (effet du paramètre a) et qu'on déplace temporellement (effet du paramètre b).

L'ondelette de Morse est définie dans le domaine fréquentiel ω (Lilly et Olhede, 2009; 2010)

$$\psi_{\beta,\gamma}(t) \Leftrightarrow \Psi_{\beta,\gamma}(\omega) = H(\omega) c_{\beta,\gamma} \omega^{\beta} e^{-\omega^{\gamma}} \quad (3.4)$$

où le doublet (β, γ) correspond aux paramètres de l'ondelette, $c_{\beta,\gamma}$ est une constante de normalisation et $H(\omega)$ est la fonction de Heaviside (fonction échelon), définie comme

$$H(\omega) = \begin{cases} 0 & \Leftrightarrow \omega < 0 \\ 1 & \Leftrightarrow \omega \geq 0 \end{cases} \quad (3.5)$$

Cette fonction $H(\omega)$ force l'ondelette à être analytique, i.e. $\Psi_{\beta,\gamma}(\omega) = 0$ pour tout $\omega < 0$.

L'ondelette est donc complexe (\mathbb{C}), impliquant que les coefficients $W(a,b)$ le sont aussi. Une conséquence intéressante est que les coefficients contiennent directement l'information de module (ou amplitude) et de phase instantanée.

On peut ainsi représenter alternativement la CWT dans le domaine fréquentiel :

$$W(a,b) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \Psi_{\beta,\gamma}^*(a\omega) S(\omega) e^{i\omega b} d\omega \quad (3.6)$$

où $S(\omega) = \int_{-\infty}^{\infty} s(t) e^{-i\omega t} dt$ est la Transformée de Fourier du signal initial $s(t)$. L'équation 3.6 correspond à la Transformée de Fourier inverse du produit scalaire, dans le domaine fréquentiel, de l'ondelette avec le signal.

La Figure 3.2 illustre les effets respectifs des paramètres β et γ de l'ondelette de Morse. Le paramètre γ peut être vu comme l'ordre du filtre; plus il est élevé, plus la courbe dans le domaine fréquentiel est étroite, résultant en une résolution fréquentielle accrue. Le paramètre β correspond aux moments nuls (de l'anglais *vanishing moments*). Il contrôle le contenu en polynômes basse fréquence; plus il est élevé, plus la courbe dans le domaine fréquentiel est amortie autour de l'origine (à la fréquence 0). Ces paramètres encodent des informations essentielles sur l'ondelette, comme la fréquence centrale d'oscillation $\omega_{\beta,\gamma} = (\beta/\gamma)^{1/\gamma}$ et la durée (sans dimension) $P_{\beta,\gamma} = \sqrt{\beta\gamma}$. Pour la suite du travail, on considère $\gamma = 20$ et $\beta = 10$. Le choix de ces valeurs a été guidé par inspection visuelle des plans temps-fréquences obtenus sur des signaux contenant des fuseaux. Cette configuration fournit un plan à la fois lisse et bien résolu en temps-fréquence, mettant en évidence les fuseaux de façon jugée optimale.

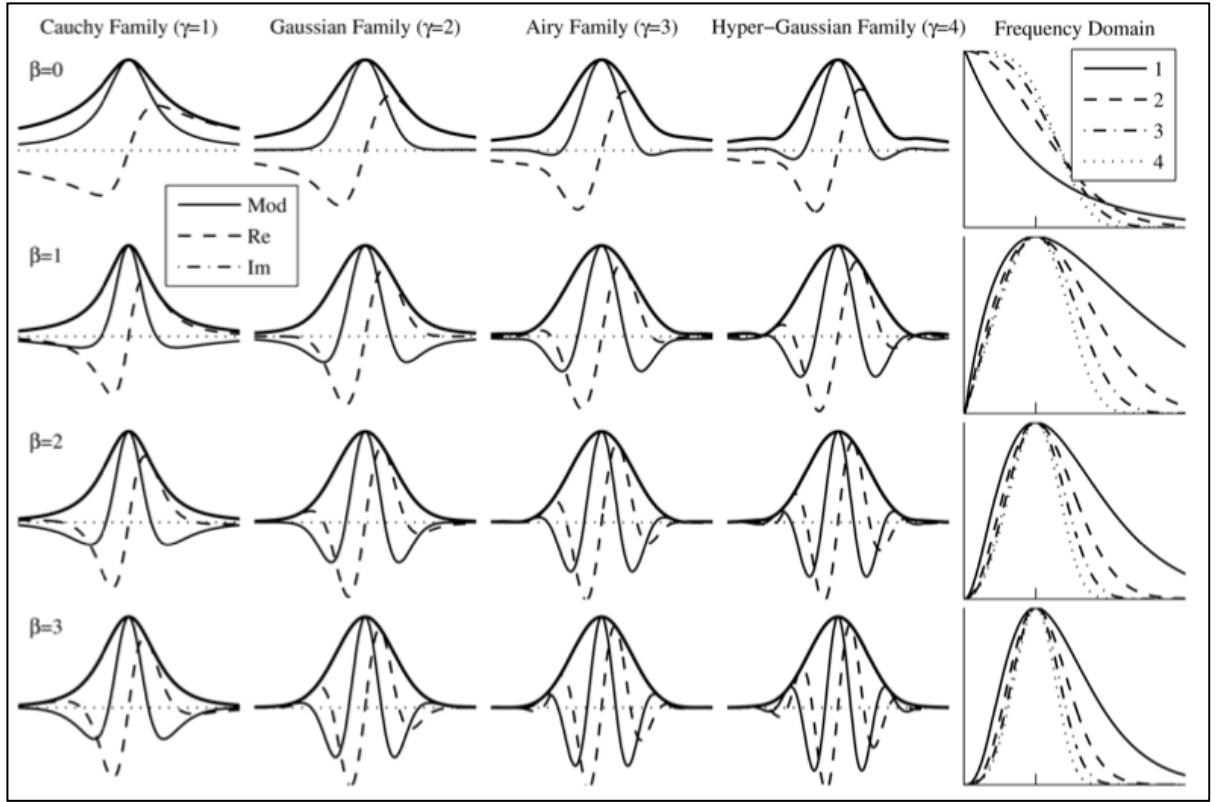


Figure 3.2 Effet des paramètres β et γ de l'ondelette de Morse généralisée
(Tirée de Lilly et Olhede, 2009, p.156)

3.3 Fonction de détection temps-fréquence

On considère la matrice $\mathbf{W}^{(m)}$ correspondant au plan temps-fréquence, obtenu par CWT couvrant la bande 10Hz-16Hz (0.1Hz de résolution), du signal $\mathbf{s}^{(m)} = \mathbf{m}^T \mathbf{S}$ du montage \mathbf{m} . Chaque élément $w_{i,j}^{(m)}$ correspond au coefficient de la CWT obtenu à la fréquence f_i et à l'instant t_j . C'est une matrice de dimension N_f lignes par N_t colonnes, où N_f est le nombre de fréquences évaluées et N_t est le nombre d'échantillons temporels.

On construit une fonction de détection $\mathbf{d}(\mathbf{t}) = \mathbf{d}^{(m)} = [d_j^{(m)}]$ à partir du plan temps-fréquence $\mathbf{W}^{(m)}$ de la topographie \mathbf{m}

$$d(t_j) = d_j^{(m)} = \max_{1 \leq i \leq N_f} \{ |w_{i,j}^{(m)}| \} \quad (3.7)$$

En d'autres termes, chaque élément $d_j^{(m)}$ correspond au plus grand module du coefficient en ondelette, $|w_{i,j}^{(m)}|$, à travers toutes les fréquences f_i et à l'instant t_j . La courbe, dans le plan temps-fréquence, correspondant aux coefficients $d_j^{(m)}$ s'appelle aussi « ridge ». La Figure 3.3 illustre cette méthode.

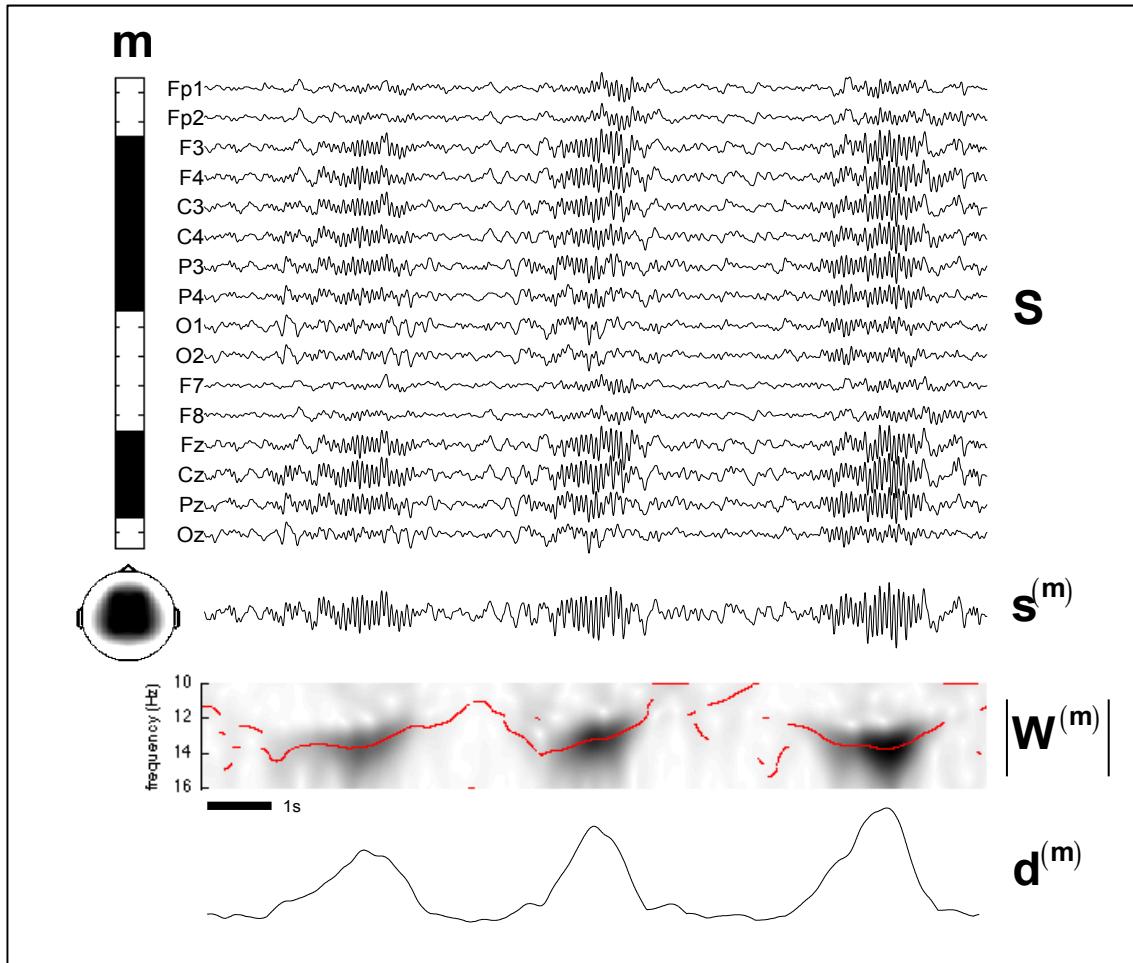


Figure 3.3 Illustration de la génération de la fonction de détection

Cette fonction $\mathbf{d}^{(m)}$ correspond ainsi à une fonction de détection $d(\mathbf{t})$ telle que décrite à la section 2.2 sur les détecteurs de type 1 : c'est l'amplitude instantanée (ou enveloppe) d'oscillations dans la bande fréquentielle des fuseaux.

3.4 Segmentation adaptative

Contrairement au principe de détection de type 1 (section 2.2), la création d'événements ici ne se fait pas par seuillage de la fonction de détection. De plus, les événements ne sont pas créés sans *a priori*, ou à l'aveugle (par exemple, en segmentant uniformément les données), comme dans le principe de détection de type 2 (section 2.3). La méthode utilisée dans le présent ouvrage consiste à créer une segmentation *adaptée* à la fonction de détection.

Pour ce faire, on paramétrise $\mathbf{d}^{(m)}$ par ses *extrema* locaux, i.e. une suite alternée de *minima* et de *maxima* locaux. Les extrema locaux se situent là où la dérivée du signal croise zéro ; on a un minimum quand la dérivée croise zéro vers les positifs et on a un maximum quand la dérivée croise zéro vers les négatifs. Si on considère la différence $\dot{\mathbf{d}} = \mathbf{d}_{2:N_t}^{(m)} - \mathbf{d}_{1:N_t-1}^{(m)}$, on peut formellement définir les extrema \mathbf{t}^{ext} , les minima \mathbf{t}^{min} et les maxima \mathbf{t}^{max} en définissant d'abord les instants qui supportent ces points :

$$\begin{aligned}\mathbf{t}^{ext} &= \{t_i \in \mathbf{t} : \dot{\mathbf{d}}(t_i) \dot{\mathbf{d}}(t_{i+1}) < 0\} \\ \mathbf{t}^{min} &= \{t_i^{ext} \in \mathbf{t}^{ext} : \dot{\mathbf{d}}(t_i^{ext}) < \dot{\mathbf{d}}(t_{i+1}^{ext})\} \\ \mathbf{t}^{max} &= \{t_i^{ext} \in \mathbf{t}^{ext} : \dot{\mathbf{d}}(t_i^{ext}) > \dot{\mathbf{d}}(t_{i+1}^{ext})\}\end{aligned}\tag{3.8}$$

Ainsi, les valeurs de la fonction de détection prises à ses extrema locaux sont définies par $\mathbf{d}^{ext} = \mathbf{d}^{(m)}(\mathbf{t}^{ext})$. Le vecteur des caractéristiques $\tilde{\mathbf{x}}_n$ peut donc être construit directement à partir de la fonction de détection $\mathbf{d}^{(m)}$:

$$\begin{aligned}
\tilde{x}_n^{position} &= t_n^{max} \\
\tilde{x}_n^{amplitude} &= d_n^{max} \\
\tilde{x}_n^{début} &= t_n^{min} \\
\tilde{x}_n^{fin} &= t_{n+1}^{min} - \Delta t \\
\tilde{x}_n^{durée} &= \tilde{x}_n^{fin} - \tilde{x}_n^{début} \\
\tilde{x}_n^{fréquence} &= f_k : \left| W_{k,j}^{(m)} \right| = \max_{1 \leq i \leq N_f} \left\{ \left| W_{i,j}^{(m)} \right| \right\}
\end{aligned} \tag{3.9}$$

On note que la fréquence de l'oscillation $\tilde{x}_n^{fréquence}$ est définie comme étant la fréquence f_k du module $|W_{k,j}^{(m)}|$ de la CWT à l'instant d'un maximum t_j^{max} . La Figure 3.4 illustre ce processus de segmentation de la fonction de détection et de la paramétrisation des événements ainsi créés. Les points bleus et rouges sont respectivement les minima et maxima locaux.

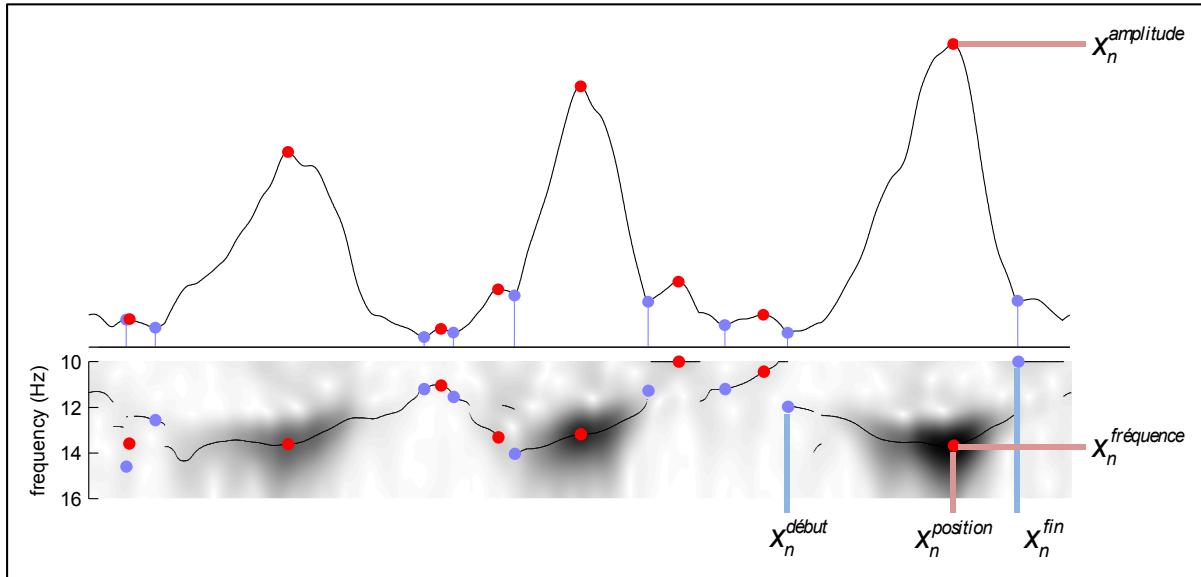


Figure 3.4 Illustration de la segmentation de la fonction de détection

3.5 Extraction des caractéristiques

Dans cette section, on définit les caractéristiques extraites pour chaque évènement $\tilde{\mathbf{x}}_n$ créé par la segmentation de la fonction de détection. Pour la première étape de détection, on définit les caractéristique d'amplitude ($\tilde{x}_n^{amplitude}$) et de rapport spectral sigma (\tilde{x}_n^{sigma}) qui seront seuillées en fixant une *p-value* sur une hypothèse nulle construite à partir des évènements se manifestant en stade REM. Le stade dans lequel chaque évènement se manifeste correspond aussi à une caractéristique (\tilde{x}_n^{stade}). Pour la deuxième étape de détection, on définit les caractéristiques de fréquence ($\tilde{x}_n^{fréquence}$) et de position spatiale médiane ($\tilde{x}_n^{médian}$) qui serviront à une classification hiérarchique. La sélection des classes se basera sur le regroupement d'une majorité d'évènements concordant temporellement avec des fuseaux marqués par l'expert. Cette concordance avec les évènements de l'expert correspond aussi à une caractéristique (\tilde{x}_n^{expert}).

3.5.1 Amplitude

La caractéristique d'amplitude, $\tilde{x}_n^{amplitude}$, correspond au maximum local de la fonction de détection $\mathbf{d}^{(\mathbf{m})}$ du montage \mathbf{m} , soit le module du coefficient en ondelette maximal dans la bande 10Hz-16Hz à l'instant d'un tel maximum local temporel (*voir* section 3.4 et Figure 3.4).

3.5.2 Rapport spectral sigma

La caractéristique de rapport spectral sigma, \tilde{x}_n^{sigma} , est inspirée de celle définie dans (Huupponen et al., 2007), à la différence près qu'elle est définie ici dans le plan temps-fréquence \mathbf{W} de la CWT, plutôt que dans le spectre de Fourier :

$$\tilde{X}_n^{\text{sigma}} = \frac{2 \max\{|\mathbf{W}|_{[10.5-16\text{Hz}, t_i]}\}}{\text{moy}\{|\mathbf{W}|_{[4-10\text{Hz}, t_i]}\} + \text{moy}\{|\mathbf{W}|_{[20-40\text{Hz}, t_i]}\}} \quad (3.10)$$

Le terme au numérateur correspond à deux fois le module du coefficient CWT maximal dans la bande 10.5-16Hz à l'instant $t_i = \tilde{X}_n^{\text{position}}$. Les deux termes au dénominateur représentent respectivement les moyennes des modules des coefficients CWT dans les bandes 4-10Hz et 20-40Hz, toujours à l'instant $t_i = \tilde{X}_n^{\text{position}}$. On veut ici favoriser les oscillations à bande spectrale étroite. En effet, certains types d'activité correspondant à du bruit physiologique ont un spectre qui peut interférer avec la bande des fuseaux et ainsi générer des faux positifs. La présence significative d'activité musculaire, modélisée par le terme $|\mathbf{W}|_{[20-40\text{Hz}, t_i]}$, ainsi que celle du rythme alpha, modélisé par le terme $|\mathbf{W}|_{[4-10\text{Hz}, t_i]}$, aura tendance à diminuer la valeur du rapport, diminuant ainsi la probabilité de présence d'un fuseau.

La Figure 3.5 illustre l'extraction des quantités définissant la caractéristique $\tilde{X}_n^{\text{sigma}}$. Le plan temps-fréquence ($|\mathbf{W}|$) est représenté, en niveaux de gris, par le module des coefficients en ondelettes calculés pour les fréquences de 4Hz à 40Hz avec une résolution de 0.1Hz. On montre en rouge la ligne de ridge de la bande 10Hz-16Hz, correspondant à la fonction de détection $d(\mathbf{t})$ telle que définie à l'équation 3.7. Un exemple d'évènement créé à partir de cette fonction est représenté par la boîte noire ($\tilde{\mathbf{X}}_n$). À droite, on montre en bleu les coefficients extraits à travers toutes les fréquences à l'instant $t_i = \tilde{X}_n^{\text{position}}$. La courbe correspond au spectre fréquentiel de l'évènement considéré, duquel on extrait la moyenne des coefficients basses fréquences $\text{moy}\{|\mathbf{W}|_{[4-10\text{Hz}, t_i]}\}$, la moyenne des coefficients hautes fréquences $\text{moy}\{|\mathbf{W}|_{[20-40\text{Hz}, t_i]}\}$ et le maximum dans la bande des fuseaux $\max\{|\mathbf{W}|_{[10.5-16\text{Hz}, t_i]}\}$.

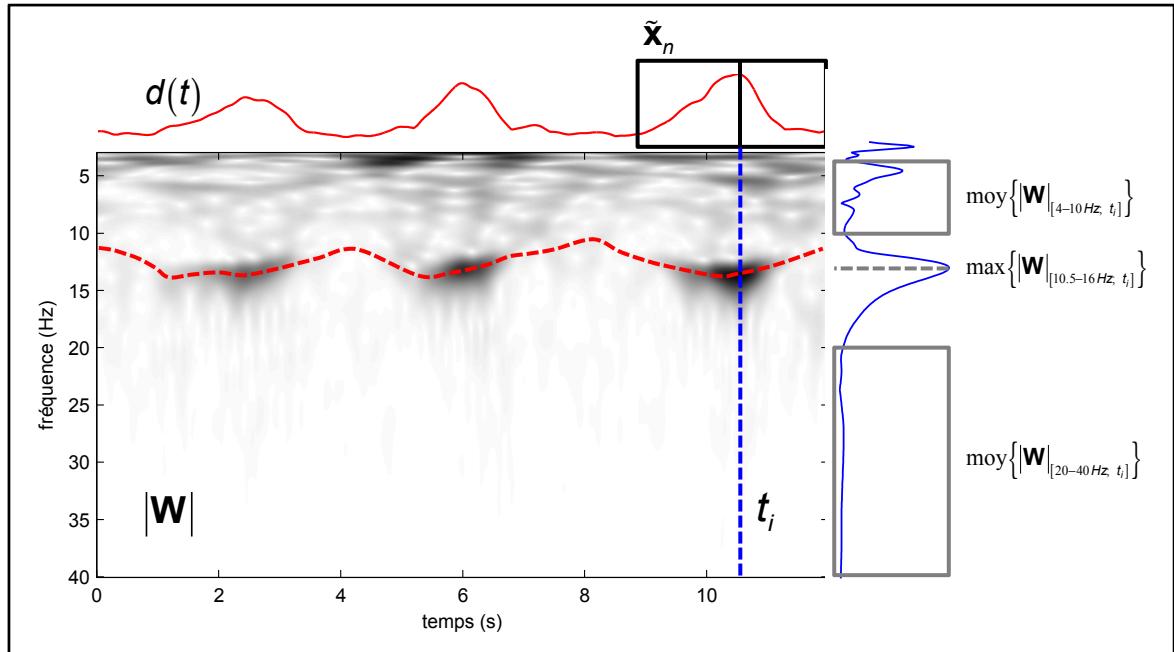


Figure 3.5 Illustration de l'extraction du rapport spectral sigma

3.5.3 Stade de sommeil

La caractéristique $\tilde{X}_n^{\text{stade}}$ correspond au stade de sommeil pendant lequel l'évènement se manifeste. Pour l'obtenir, on fait appel ici à l'expert qui doit générer l'hypnogramme de sommeil selon les règles de l'AASM (voir Figure 3.7, A). On a ainsi, par tranche de 20 secondes couvrant toute la nuit, une classification du sommeil en 6 stades: stade 0 (éveil), stade 1 (*Non-Rapid Eye Movement sleep*, NREM1), stade 2 (NREM2), stade 3 (NREM3), stade 4 (NREM4) et stade 5 (sommeil paradoxal ou *Rapid Eye Movement sleep*, REM). Il est donc possible d'attribuer à chaque évènement \tilde{X}_n la caractéristique $\tilde{X}_n^{\text{stade}}$ du stade de sommeil correspondant au segment qui inclut cet évènement. Cette caractéristique pourrait aussi être générée par un classificateur automatique des stades de sommeil.

3.5.4 Fréquence

La caractéristique $\tilde{x}_n^{\text{fréquence}}$ est définie comme la fréquence correspondant au maximum local dans le plan temps-fréquence CWT, le même maximum local qui définit $\tilde{x}_n^{\text{position}}$ et $\tilde{x}_n^{\text{amplitude}}$ (*voir* section 3.4 et Figure 3.4). Cette caractéristique est utilisée pour la classification hiérarchique qui nécessite le calcul de distance entre chaque paire d'événements, impliquant la somme de caractéristiques pouvant avoir des unités physiques différentes (*voir* section 3.7). Il importe donc de normaliser les valeurs de manière à les rendre sans unité. La fréquence normalisée $x_n^{\text{fréquence}0}$ est définie comme suit :

$$x_n^{\text{fréquence}0} = \frac{x_n^{\text{fréquence}} - f_{\text{MIN}}}{f_{\text{MAX}} - f_{\text{MIN}}} \quad (3.11)$$

où $f_{\text{MIN}} = 10\text{Hz}$ et $f_{\text{MAX}} = 16\text{Hz}$, correspondant à la bande fréquentielle utilisée pour la création des événements \mathbf{x}_n (*voir* section 3.3). Ainsi, $x_n^{\text{fréquence}0}$ est confiné dans l'intervalle $[0; 1]$.

3.5.5 Position médiane

La caractéristique $\tilde{x}_n^{\text{médian}}$ correspond à la position sur l'axe antéro-postérieur, ou axe médian, de l'activité oscillante dans la bande des fuseaux. Pour déterminer cette position, on considère d'abord une fenêtre de 500ms centrée autour de la position $\tilde{x}_n^{\text{position}}$ de l'événement considéré, incluant toutes les électrodes EEG. Cette fenêtre consiste en une matrice \mathbf{S} de N_c lignes correspondant au nombre de capteurs (16 avec le montage original) et N_t colonnes correspondant au nombre d'échantillons temporels (128 pour une fréquence d'échantillonnage de 256Hz). Aux signaux de tous les capteurs, on applique finalement un filtre Butterworth d'ordre 5 passe-bande 10Hz-16Hz.

On veut extraire ici de façon robuste la distribution sur le scalp uniquement de l'oscillation de type fuseau, i.e. l'oscillation qui se manifeste simultanément et de manière parfaitement corrélée sur toutes les électrodes. La topographie obtenue par une simple analyse de variance indépendamment sur chaque électrode ne fournit pas une telle spécificité, car elle peut inclure plusieurs composantes n'ayant aucun lien avec l'oscillation d'intérêt. L'analyse en composantes principales (*Principal Component Analysis*, PCA) permet une telle décomposition en composantes décorrélées entre elles.

La PCA est réalisée via la décomposition en valeurs singulières (*Singular Value Decomposition*, SVD). La SVD est une factorisation $\mathbf{S} = \mathbf{U}\Sigma\mathbf{V}^T$, où \mathbf{U} et \mathbf{V} sont des matrices carrées orthogonales ($\mathbf{U}^T\mathbf{U} = \mathbf{I}$ et $\mathbf{V}^T\mathbf{V} = \mathbf{I}$), et Σ est une matrice dont la diagonale contient les valeurs singulières σ . La matrice \mathbf{U} est de dimension N_c par N_c et la matrice \mathbf{V} est de dimension N_t par N_t . La première colonne de \mathbf{U} et \mathbf{V} , les vecteurs \mathbf{u}_1 et \mathbf{v}_1 respectivement, forment, avec la première valeur singulière σ_1 , la première composante principale de la matrice \mathbf{S} par le produit $\mathbf{u}_1\sigma_1\mathbf{v}_1^T$; on peut ainsi interpréter \mathbf{v}_1 , \mathbf{u}_1 et σ_1 comme étant respectivement le décours temporel, le montage (ou topographie) et la variance de la première composante principale.

Chaque composante du vecteur \mathbf{u}_1 correspond à un capteur. On peut attribuer à chacun une coordonnée x et une coordonnée y , correspondant à des coordonnées spatiales sur un plan virtuel situé au-dessus de la tête (voir Figure 3.6). L'axe des abscisses (coordonnées x) correspond à l'axe latéral (gauche-droite) et l'axe des ordonnées (coordonnées y) correspond à l'axe médian (arrière-avant). Les coordonnées sont normalisées, confinées dans un cercle de rayon 0.5 modélisant la circonférence de la tête et respectant le système 10-20. Ces données sont extraites via le logiciel FieldTrip² (Oostenveld et al., 2011). On considère que l'élément correspondant à la valeur maximale (en valeur absolue) de \mathbf{u}_1 correspond au capteur sur lequel l'oscillation se manifeste. L'information qu'on garde est la coordonnée sur l'axe médian (l'ordonnée y), formant la caractéristique $\tilde{x}_n^{\text{médian}}$. On pose ici l'hypothèse que la

² Fichier de montage EEG1005.lay

caractérisation antérieure-postérieure est plus spécifique, pour les fuseaux, que la caractérisation gauche-droite.

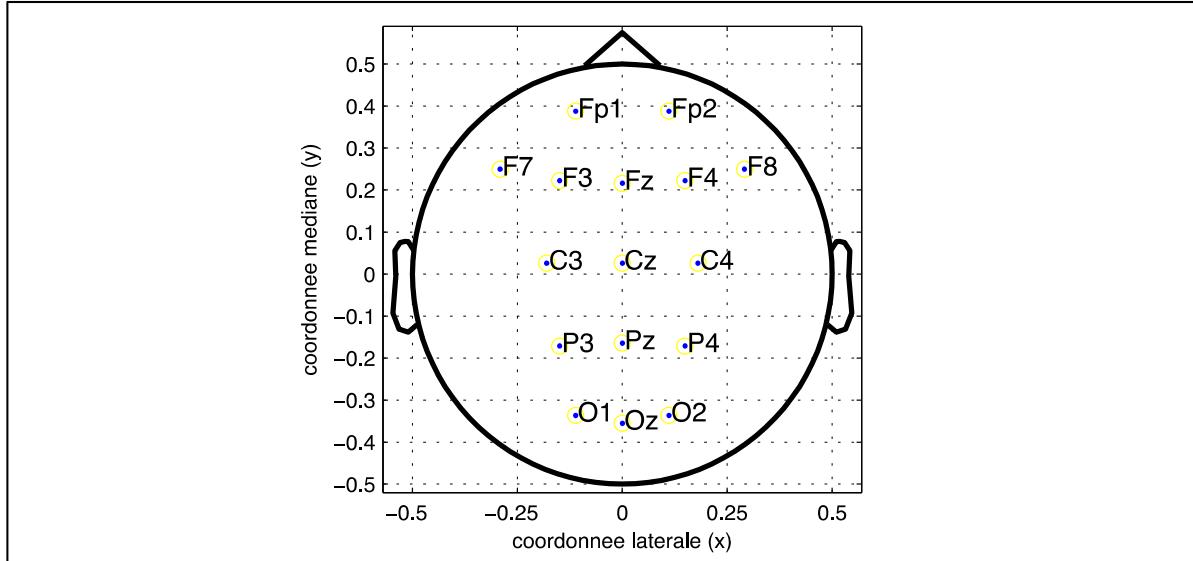


Figure 3.6 Position des capteurs sur un plan virtuel au-dessus de la tête en termes de coordonnées médianes (ordonnées) et de coordonnées latérales (abscisses)

Comme dans le cas de la caractéristique de fréquence (voir section 3.5.4), la position médiane est utilisée pour la classification hiérarchique, ce qui implique la nécessité de normaliser les valeurs de manière à les rendre sans unité. La position médiane normalisée $x_n^{\text{médian}0}$ est définie comme suit :

$$x_n^{\text{médian}0} = \frac{x_n^{\text{médian}} - y_{MIN}}{y_{MAX} - y_{MIN}} \quad (3.12)$$

où $y_{MIN} = -0.5$ et $y_{MAX} = 0.5$, correspondant respectivement aux positions limites minimale et maximale de $x_n^{\text{médian}}$. Ainsi, $x_n^{\text{médian}0}$ est confiné dans l'intervalle $[0; 1]$.

3.5.6 Expert

La caractéristique $\tilde{X}_n^{\text{expert}}$ consiste en une valeur logique qui est en état *vrai* (1) si l'évènement est en concordance temporelle avec un fuseau marqué par un expert. Pour l'obtenir, on demande à un expert de marquer des fuseaux sur les capteurs Fz, Cz et Pz selon les règles de R&K et AASM. Chaque fuseau marqué est caractérisé par un instant de début, un instant de fin et le capteur sur lequel il est observé. On obtient en somme un ensemble \mathbf{U} d'évènements $\mathbf{u}_m = [u_m^{\text{début}} \ u_m^{\text{fin}} \ u_m^{\text{capteur}}]^T$ identifiés par l'expert.

Cet ensemble permet de déterminer la concordance temporelle entre \mathbf{U} et $\tilde{\mathbf{X}}$ selon la logique suivante : deux évènements $\tilde{\mathbf{x}}_n$ et \mathbf{u}_m concordent si $\tilde{X}_n^{\text{début}} < u_m^{\text{fin}}$ et $\tilde{X}_n^{\text{fin}} > u_m^{\text{début}}$. On peut ainsi formuler la caractéristique $\tilde{X}_n^{\text{expert}}$ comme suit :

$$\tilde{X}_n^{\text{expert}} = 1 \Leftrightarrow \exists \mathbf{u}_m \in \mathbf{U} : \tilde{X}_n^{\text{début}} < u_m^{\text{fin}} \wedge \tilde{X}_n^{\text{fin}} > u_m^{\text{début}} \quad (3.13)$$

Si cette condition est rencontrée, $\tilde{X}_n^{\text{expert}}$ est donc à l'état logique *vrai* (1). Sinon, $\tilde{X}_n^{\text{expert}}$ est à l'état logique *faux* (0). On note que la caractéristique u_m^{capteur} n'est pas prise en compte; on ne considère que la concordance temporelle et non spatiale, puisque le montage de détection couvre les électrodes Fz, Cz et Pz.

3.6 Sélection sensible: seuillage par *p-value*

Cette première phase de sélection repose sur les caractéristiques $\tilde{X}_n^{\text{amplitude}}$ et $\tilde{X}_n^{\text{sigma}}$. On considère cette étape comme étant *sensible*, car on sait que les fuseaux tendent à *maximiser* ces caractéristiques. En sélectionnant un seuil assez bas, on peut atteindre une sensibilité arbitrairement grande. La sélection consiste à appliquer un seuil déterminé à partir d'une hypothèse nulle (H_0) : « l'évènement $\tilde{\mathbf{x}}_n$ n'est *pas* un fuseau ». Celle-ci est construite à partir d'un ensemble d'évènements obtenus en stade REM dont on sait qu'il ne contient aucun vrai

fuseau. En fixant une *p-value* sur H_0 , on obtient les seuils à appliquer sur chaque caractéristique.

Afin de définir l'hypothèse nulle, on considère $\tilde{\mathbf{x}}_0^{\text{amplitude}}$ et $\tilde{\mathbf{x}}_0^{\text{sigma}}$ comme étant les vecteurs des valeurs de chaque caractéristique pour tous les évènements exclusivement en stade REM, i.e. dont $\tilde{x}_n^{\text{stade}} = \text{REM}$ (voir section 3.5.3 et Figure 3.7, A). On calcule leurs histogrammes respectifs $\mathbf{h}_0^{\text{amplitude}}$ et $\mathbf{h}_0^{\text{sigma}}$, correspondant au décompte d'évènements ayant chaque valeur de chaque caractéristique (voir Figure 3.7, B). Ces derniers sont, à un facteur près, des densités de probabilité (*Probability Density Function*, PDF). On calcule ces histogrammes indépendamment pour chaque caractéristique et non un histogramme conjoint; on considère donc que ces caractéristiques sont statistiquement indépendantes. Or, il a déjà été montré qu'elles ont une dépendance statistique faible, avec un coefficient de corrélation d'environ 0.25 (Huupponen et al., 2007), ce qui justifie notre hypothèse de travail.

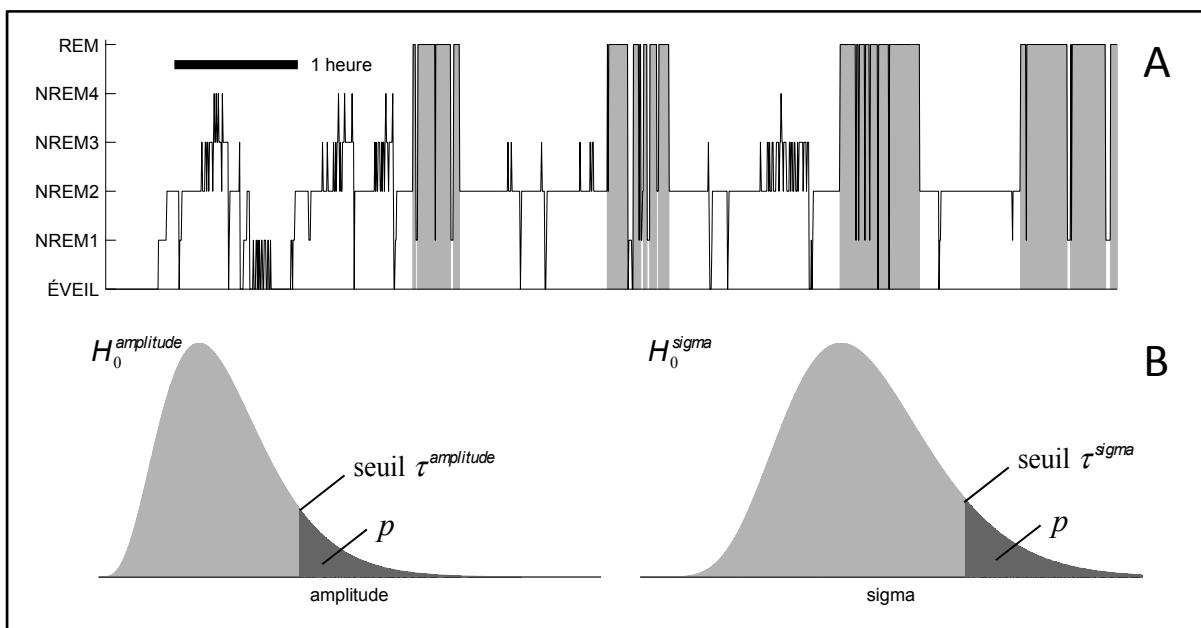


Figure 3.7 Illustration de l'obtention des seuils pour l'étape de pré-détection
A: hypnogramme généré par un expert, avec en gris les périodes REM.
B: hypothèses nulles ($p = 0.1$ illustré)

À partir de ces histogrammes, on calcule les fonctions de répartition (*Cumulative Distribution Function*, CDF) respectives $\mathbf{c}_0^{\text{amplitude}}$ et $\mathbf{c}_0^{\text{sigma}}$ par une somme cumulative:

$$\mathbf{c}_0[n] = \frac{1}{N} \sum_{m=1}^n \mathbf{h}_0[m] \quad (3.14)$$

où N est le nombre d'évènements en REM. Ainsi, si on considère chaque caractéristique comme une variable aléatoire X qui peut prendre des valeurs x et que la CDF est une fonction de x , on a que $\mathbf{c}_0(x)$ correspond à la probabilité $P(X \leq x)$ si H_0 est vraie. De manière équivalente, la valeur $1 - \mathbf{c}_0(x)$ correspond à la probabilité $P(X \geq x)$ si H_0 est vraie:

$$P(X \geq x) = 1 - \mathbf{c}_0(x) \quad (3.15)$$

Cette probabilité est la *p-value* et est illustrée à la Figure 3.7 par les régions en gris foncé sur les courbes du bas. En fixant une *p-value* à une valeur p , on détermine la région des valeurs x de X pour lesquelles on rejette l'hypothèse nulle H_0 . Pour chaque caractéristique, le seuil τ est ainsi déterminé comme étant la valeur limite x_p qui rejette H_0 pour une *p-value* p fixée :

$$\tau = x_p : P(X \geq x_p) = p \quad (3.16)$$

Pour les deux caractéristiques, la valeur p est la même, mais on obtient deux seuils différents : $\tau^{\text{amplitude}}$ et τ^{sigma} . On représente la sélection dans l'étape de pré-détection comme l'ajout d'une caractéristique $\tilde{X}_n^{\text{candidat}}$ à chaque évènement $\tilde{\mathbf{x}}_n$ correspondant à la valeur logique

$$\tilde{X}_n^{\text{candidat}} = (\tilde{X}_n^{\text{amplitude}} \geq \tau^{\text{amplitude}}) \wedge (\tilde{X}_n^{\text{sigma}} \geq \tau^{\text{sigma}}) \quad (3.17)$$

Ainsi, un état *vrai* ($\tilde{X}_n^{candidat} = 1$) signifie que l'hypothèse nulle H_0 est rejetée pour les deux caractéristiques. L'ensemble \mathbf{X} des événements sélectionnés de $\tilde{\mathbf{X}}$ peut être défini comme

$$\mathbf{X} = \{\mathbf{x}_m\} = \{\tilde{\mathbf{x}}_n \in \tilde{\mathbf{X}} : \tilde{X}_n^{candidat} = 1\} \quad (3.18)$$

3.7 Sélection spécifique: classification hiérarchique

Dans cette seconde phase de sélection, on utilise les caractéristiques normalisées $x_n^{fréquence0}$ et $x_n^{médian0}$ (voir sections 3.5.4 et 3.5.5) de l'ensemble \mathbf{X} des événements sélectionnés par seuillage (voir section 3.6). Cette phase définit la spécificité de notre approche. En effet, à partir d'un ensemble d'événements répondant aux critères d'un fuseau (amplitude, rapport spectral, fréquence, montage), on sélectionne ici un sous-ensemble qui *ressemble* à un ensemble d'événements marqués par un expert. Pour ce faire, on effectue une classification hiérarchique "agglomérative" de \mathbf{X} sur les vecteurs $\mathbf{x}_n = [x_n^{fréquence0} \ x_n^{médian0}]^T$ et on sélectionne les classes qui regroupent une majorité d'événements concordant avec ceux d'un expert.

La classification ascendante (ou agglomérative) hiérarchique (CAH) est une méthode de classification non-supervisée qui crée une hiérarchie de classes par agglomération. Au départ, à la base de la hiérarchie, on a l'ensemble \mathbf{X} des N éléments \mathbf{x}_n qui correspondent initialement à N classes singulaires (contenant un seul élément). Chaque étape de la CAH, donc chaque niveau de la hiérarchie en ascension, correspond à l'agglomération des deux classes les moins *distantes*. Le dernier niveau de la hiérarchie correspond à l'unique classe qui regroupe tous les éléments. La CAH est caractérisée par deux concepts : la *métrique*, qui permet de calculer la distance (ou dissimilitude) entre les éléments de l'ensemble \mathbf{X} , et la *liaison*, qui est aussi une forme de dissimilitude, mais cette fois entre des ensembles d'événements (qui sont des sous-ensembles de \mathbf{X}).

La métrique utilisée, qui calcule la distance $d(\mathbf{x}_n, \mathbf{x}_m)$ entre 2 éléments \mathbf{x}_n et \mathbf{x}_m , est la distance euclidienne définie comme

$$d(\mathbf{x}_n, \mathbf{x}_m) = \|\mathbf{x}_n - \mathbf{x}_m\|_2 = \sqrt{\sum_{i=1}^{N_p} (x_n^{(i)} - x_m^{(i)})^2} \quad (3.19)$$

où N_p est le nombre de paramètres, ou caractéristiques, des vecteurs \mathbf{x}_n et \mathbf{x}_m . Puisque les seules caractéristiques considérées pour la classification sont $x_n^{\text{fréquence}0}$ et $x_n^{\text{médian}0}$, on a $N_p = 2$. En somme, la distance peut être explicitement exprimée comme suit :

$$d(\mathbf{x}_n, \mathbf{x}_m) = \sqrt{(x_n^{\text{fréquence}0} - x_m^{\text{fréquence}0})^2 + (x_n^{\text{médian}0} - x_m^{\text{médian}0})^2} \quad (3.20)$$

La liaison utilisée, qui calcule la dissimilitude $L(\mathbf{A}, \mathbf{B})$ entre deux classes $\mathbf{A} \subset \mathbf{X}$ et $\mathbf{B} \subset \mathbf{X}$, est la liaison moyenne:

$$L(\mathbf{A}, \mathbf{B}) = \frac{1}{|\mathbf{A}||\mathbf{B}|} \sum_{\mathbf{x}_a \in \mathbf{A}} \sum_{\mathbf{x}_b \in \mathbf{B}} d(\mathbf{x}_a, \mathbf{x}_b) \quad (3.21)$$

où $|\mathbf{A}|$ et $|\mathbf{B}|$ représentent le nombre d'éléments dans les ensembles \mathbf{A} et \mathbf{B} respectivement. Ainsi, la liaison, ou dissimilitude, correspond à la moyenne des distances entre chaque paire d'éléments possible entre les deux classes \mathbf{A} et \mathbf{B} . Chaque étape de la CAH consiste donc à grouper les deux classes dont la liaison L est la plus faible. D'autres types de liaisons existent, comme la liaison minimale et la liaison maximale. Cependant, celles-ci peuvent ne pas être adaptées dans certains cas, notamment lorsque les éléments sont agencés dans l'espace de sorte qu'ils se suivent "à la chaîne" (causant un phénomène d'enchaînement, ou *chaining*, dans le cas de la liaison minimale) ou lorsqu'ils y a des points aberrants, des éléments anormalement "loins" des autres (l'agglomération tendant à former des classes d'égales

grandeur dans le cas de la liaison maximale). La liaison moyenne offre un compromis entre ces deux cas de figure (Timm, 2002).

La Figure 3.8 suivante illustre la CAH avec un exemple où \mathbf{X} serait composé de 20 événements \mathbf{x}_n ayant chacun les caractéristiques normalisées $x_n^{\text{fréquence}0}$ et $x_n^{\text{médian}0}$. Le graphique de gauche montre la position de chaque événement, symbolisé par une lettre, dans l'espace euclidien à deux dimensions. L'image du milieu montre la matrice de toutes les distances $d(\mathbf{x}_n, \mathbf{x}_m)$ possibles entre chaque paire d'événements. Les fonctions utilisées pour la CAH sont celles incluses dans la boîte à outils statistique du logiciel Matlab³.

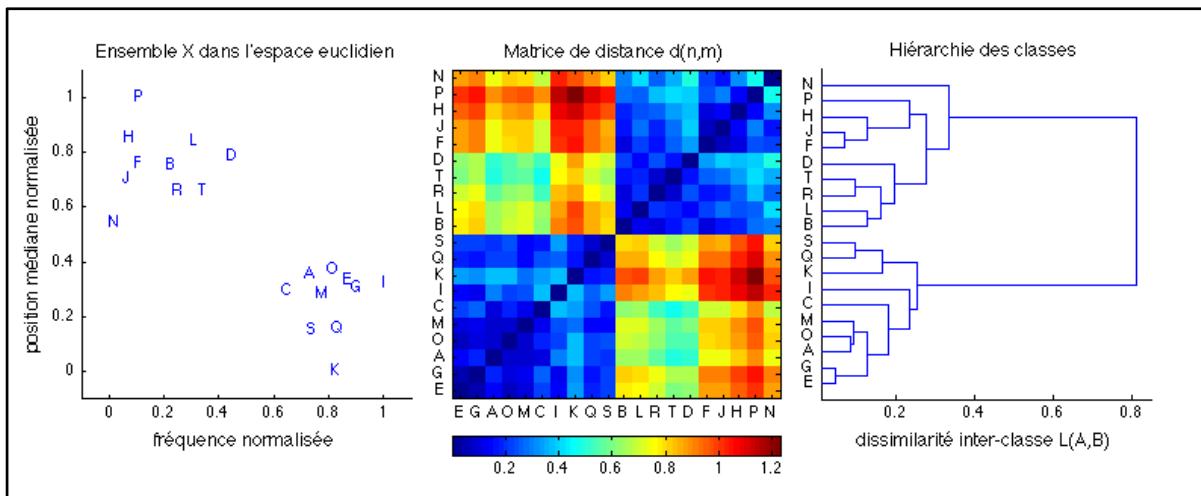


Figure 3.8 Illustration de la classification ascendante hiérarchique (CAH)

Le graphique de droite montre la hiérarchie des classes, ou dendrogramme ; au premier niveau (à gauche) on retrouve tous les événements, correspondant à autant de classes singulaires, et au dernier niveau (à droite), les deux dernières classes sont regroupées en une seule. Les abscisses correspondent à la dissimilitude inter-classe; la hauteur de chaque embranchement (structure en forme de U renversé) correspond à la valeur de liaison $L(\mathbf{A}, \mathbf{B})$ entre les ensembles jumelés.

³ MATLAB and Statistics Toolbox Release 2010a, The MathWorks, Inc., Natick, Massachusetts, United States.

La construction de la hiérarchie complète se termine avec une classe unique regroupant tous les éléments. Pour obtenir une classification, il faut donc arrêter l'agglomération quand on rencontre un certain critère. Dans le présent travail, on utilise un critère d'*uniformité* dans la taille des classes. Ainsi, on cherche une classification de sorte que les éléments soient uniformément distribués à travers les classes. Pour ce faire, on fonctionne de manière descendante ; on débute avec le dendrogramme complet, i.e. par l'unique classe (à droite du graphique de droite à la Figure 3.8), et on défait successivement chaque jonction, jusqu'à ce que le rapport de taille des deux plus grandes classes soit supérieur à un facteur r :

$$\frac{|\mathbf{B}|}{|\mathbf{A}|} \geq r \quad (3.22)$$

où \mathbf{A} est la plus grande classe et \mathbf{B} est la deuxième plus grande classe. Ainsi, on a la condition $0 \leq r \leq 1$ puisque $|\mathbf{A}| \geq |\mathbf{B}|$. Pour la suite, on fixe $r = 0.6$. Dans notre exemple de la Figure 3.8, on voit aisément que ce critère fournirait deux classes $\mathbf{A} = [A, C, E, G, I, K, M, O, Q, S]$ et $\mathbf{B} = [B, D, F, H, J, L, N, P, R, T]$ avec $|\mathbf{B}|/|\mathbf{A}| = 1 > r$. Au final, la classification consiste à attribuer la caractéristique x_n^{classe} à chaque événement sous la forme d'un numéro.

La sélection des classes repose sur la distribution, à travers les classes, d'événements concordant avec ceux marqués par un expert, i.e. dont la caractéristique x_n^{expert} est à l'état *vrai* (voir section 3.5.6). Ainsi, on sélectionne les classes d'événements *ressemblant* à des événements marqués par un expert par rapport aux caractéristiques $x_n^{\text{fréquence}}$ et $x_n^{\text{médian}}$. Pour ce faire, on réordonne les classes en fonction de leur contenu en événements expert ; la classe numéro 1 est maintenant celle contenant le plus d'événements pour lesquels $x_n^{\text{expert}} = 1$. On ajoute ensuite la caractéristique logique suivante :

$$x_n^{\text{classe-expert}} = x_n^{\text{classe}} \leq N_{\text{classe}} \quad (3.23)$$

où N_{classe} correspond au nombre de classes qui regroupent au moins 80% de tous les événements dont $x_n^{expert} = 1$. Au final, les événements sélectionnés ont ceux dont cette caractéristique est à l'état *vrai*, i.e. $x_n^{classe-expert} = 1$.

Dans la base de données utilisée, on possède un marquage visuel complet de tous les fuseaux par l'expert. Dans un premier temps, on effectue la sélection supervisée des classes en utilisant tous ces marqueurs de l'expert (marquage exhaustif). La performance de détection résultante de cette sélection correspond à une performance contrôle (référence). Dans un deuxième temps, afin d'évaluer l'impact du nombre d'événements fournis par l'expert, on simule un marquage partiel en sélectionnant aléatoirement un sous-ensemble des fuseaux de l'expert. On s'intéresse à l'écart des mesures de performance obtenue avec un marquage partiel par rapport à celles obtenues avec un marquage exhaustif.

3.8 Résumé de la méthode

On résume ici les étapes de la méthodologie proposée pour la détection des fuseaux du sommeil. On possède au départ les signaux EEG mesurés simultanément en certains points sur le scalp. On applique un montage à ces signaux, représentant l'activité intégrée de régions étendues et réduisant la dimension (ou complexité) du problème (section 3.1). Sur ce signal, on applique la CWT qui génère un plan temps-fréquence couvrant la bande des fuseaux, de 10Hz à 16Hz (section 3.2). On extrait de ce plan, à chaque instant, l'amplitude du coefficient en ondelette maximum en fréquence. La fonction résultante représente l'enveloppe des oscillations spectralement dominantes dans la bande des fuseaux (section 3.3). On segmente cette fonction à partir de ses extrema locaux: chaque segment (qu'on nomme événement) débute à un minimum, est positionné au maximum suivant et se termine au minimum suivant (section 3.4).

On attribue à chaque segment (évenement) des caractéristiques: amplitude, rapport spectral sigma, stade de sommeil, fréquence, position médiane (axe antéro-postérieur) et concordance avec un événement de l'expert (section 3.5). L'amplitude et la fréquence sont obtenues du

coefficent en ondelette du maximum du segment de fonction de l'évènement. Le rapport spectral sigma correspond à l'amplitude normalisée par l'amplitude aux basses (4Hz-10Hz) et hautes (20Hz-40Hz) fréquences (section 3.5.2). Le stade de sommeil est obtenu de l'hypnogramme généré par un expert; tout évènement se situant dans une période marquée d'un stade se voit attribuer ce stade (section 3.5.3). La position médiane correspond à la coordonnée antéro-postérieure du maximum de la première composante principale (spatiale) sur 500ms des signaux multicanaux filtrés dans la bande des fuseaux (section 3.5.5). La concordance avec l'expert est une valeur logique (vrai ou faux) qui est à l'état vrai si l'évènement concorde (par recouvrement temporel) avec au moins un de quelques fuseaux identifiés par un expert (section 3.5.6).

La première étape de sélection consiste à déterminer un seuil pour chacune des caractéristiques d'amplitude et de rapport spectral sigma. Ce seuil est obtenu en fixant une p-value ($p < 0.1$) sur l'hypothèse nulle "l'évènement n'est pas un fuseau". On prend comme population d'évènements non-fuseaux ceux se manifestant en stade REM. Les évènements dont les deux caractéristiques franchissent leur seuil respectif sont identifiés comme fuseaux candidats (section 3.6). La deuxième étape de sélection consiste à regrouper entre eux ces candidats par classification ascendante hiérarchique. Les évènements sont classés selon leur similitude en termes de fréquence et de position spatiale (axe antéro-postérieur). Les classes sélectionnées comme fuseaux sont celles regroupant au moins 80% des évènements concordant avec ceux de l'expert (section 3.7).

3.9 Évaluation de la performance

La performance de détection est évaluée par rapport à l'ensemble **U** des évènements marqués par un expert sur Fz, Cz et Pz. La caractéristique logique $\tilde{X}_n^{\text{expert}}$ identifie les évènements de $\tilde{\mathbf{X}}$ concordant temporellement avec ces évènements experts (*voir* section 3.5.6). On considère la caractéristique logique $\tilde{X}_n^{\text{sélection}}$ comme identifiant les évènements considérés comme fuseaux par le détecteur. Dans la première phase de détection, on a $\tilde{X}_n^{\text{sélection}} = \tilde{X}_n^{\text{candidat}}$

(voir section 3.6) et dans la deuxième phase de détection, on a $\tilde{X}_n^{\text{sélection}} = \tilde{X}_n^{\text{classe-expert}}$ (voir section 3.7).

À partir de ces identifiants, on crée une caractéristique supplémentaire $\tilde{X}_n^{\text{concordance}}$ qui identifie chaque évènement comme étant un vrai négatif (VN), un vrai positif (VP), un faux positif (FP) ou un faux négatif (FN) selon les règles logiques suivantes:

$$\begin{aligned}
 \tilde{X}_n^{\text{concordance}} = \text{VN} &\Leftrightarrow \tilde{X}_n^{\text{expert}} = 0 \wedge \tilde{X}_n^{\text{sélection}} = 0 \\
 \tilde{X}_n^{\text{concordance}} = \text{VP} &\Leftrightarrow \tilde{X}_n^{\text{expert}} = 1 \wedge \tilde{X}_n^{\text{sélection}} = 1 \\
 \tilde{X}_n^{\text{concordance}} = \text{FP} &\Leftrightarrow \tilde{X}_n^{\text{expert}} = 0 \wedge \tilde{X}_n^{\text{sélection}} = 1 \\
 \tilde{X}_n^{\text{concordance}} = \text{FN} &\Leftrightarrow \tilde{X}_n^{\text{expert}} = 1 \wedge \tilde{X}_n^{\text{sélection}} = 0
 \end{aligned} \tag{3.24}$$

Le décompte des VN, VP, FP et FN donne respectivement les quantités N_{VN} , N_{VP} , N_{FP} et N_{FN} qui servent à calculer les mesures de performance présentées à la section 2.5.

CHAPITRE 4

RÉSULTATS

4.1 Marquage de l'expert: sommeil et fuseaux

La base de données utilisée est extraite du projet SOMMEM (SOMmeil et MÉMmoire) réalisé à l'Hôpital du Sacré-Coeur de Montréal et mené par les professeurs Julie Carrier, Ph.D., et Julien Doyon, Ph.D., du département de psychologie de l'Université de Montréal. Pour le présent travail, neuf nuits entières de sujets en bonne santé ayant dormi en laboratoire ont été utilisées (7 femmes, 2 hommes, moyenne d'âge 22.6 ans \pm 2.4 ans). Un expert a visuellement classé chaque segment de 20 secondes en un des six stades de sommeil : éveil (0), NREM1 (1), NREM2 (2), NREM3 (3), NREM4 (4) et REM (5). Le résultat est l'hypnogramme et est présenté, pour chaque sujet, à la Figure 4.1 A. L'hypnogramme qualifie la structure du sommeil en mesurant la proportion de chaque stade pour la nuit entière. Pour des nuits de 489.0 ± 36.2 minutes (8.15 ± 0.60 heures), on trouve 39.7 ± 35.2 minutes ($7.64\% \pm 6.41\%$) d'éveil, 25.9 ± 17.5 minutes ($5.07\% \pm 3.13\%$) de NREM1, 274.1 ± 27.4 minutes ($55.17\% \pm 5.88\%$) de NREM2, 37.3 ± 20.2 minutes ($7.56\% \pm 4.12\%$) de NREM3, 6.8 ± 6.9 minutes ($1.36\% \pm 1.34\%$) de NREM4 et 105.2 ± 26.8 minutes ($21.34\% \pm 6.01\%$) de REM. Ces pourcentages sont illustrés pour chaque sujet à la Figure 4.1 B. Les nombres en détail sont compilés dans le Tableau-A II-1 de l'ANNEXE II.

L'expert a aussi marqué visuellement les fuseaux sur les dérivations Fz, Cz et Pz. Pour les neuf sujets, on a un total de 1039 (115 ± 116) fuseaux marqués sur Fz, 2103 (234 ± 190) fuseaux marqués sur Cz et 2484 (276 ± 203) fuseaux marqués sur Pz, pour un grand total de 5626 (625 ± 460) fuseaux marqués, toutes électrodes confondues. En contrôlant les doublons, i.e. les fuseaux marqués sur plus d'une électrode qui concordent temporellement, on a un total de 3514 (390 ± 263) fuseaux qu'on dit *distincts*. On trouve le décompte de ces fuseaux de Fz, Cz, Pz et distincts, pour chaque sujet, à la Figure 4.1 C (voir également le Tableau-A II-2 de l'ANNEXE II).

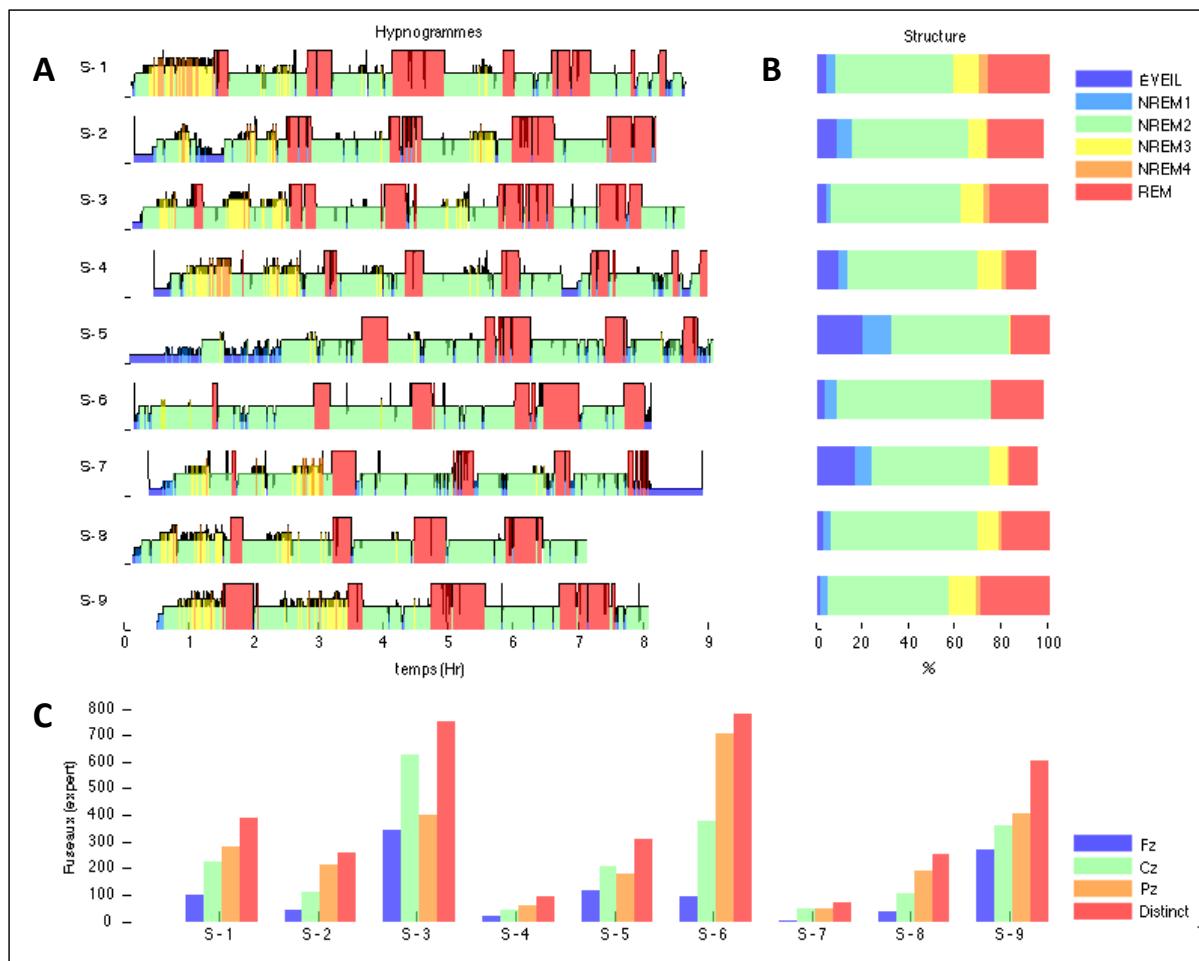


Figure 4.1 Structure du sommeil des neuf sujets de la base de données
 A: hypnogrammes de nuit entière générés par l'expert. B: quantité de chaque stade de sommeil en pourcentage de la nuit. C: quantité de fuseaux marqués par l'expert

On remarque que la quantité de fuseaux marqués varie grandement d'un sujet à l'autre. La tendance générale est une plus grande quantité de fuseaux sur Pz et une plus faible quantité sur Fz. La quantité de fuseaux distincts ne correspond clairement pas à la somme de Fz, Cz et Pz, signifiant qu'un fuséau est en général vu par au moins deux électrodes.

4.2 Montage de détection

L'algorithme de détection présenté au chapitre 3 est appliqué indépendamment pour chaque sujet. Afin de démontrer la faisabilité de l'utilisation du montage de détection tel que décrit à la section 3.1, on construit pour chaque sujet six fonctions de détection correspondant à autant de montages de détection \mathbf{m}_1 , \mathbf{m}_2 , \mathbf{m}_3 , \mathbf{m}_4 , \mathbf{m}_5 et \mathbf{m}_6 . \mathbf{m}_1 correspond aux électrodes frontales Fp1, Fp2, F7 et F8, \mathbf{m}_2 correspond aux électrodes occipitales O1, O2 et Oz, \mathbf{m}_3 correspond aux électrodes F3, F4, C3, C4, P3, P4, Fz, Cz et Pz, \mathbf{m}_4 correspond uniquement à Fz, \mathbf{m}_5 correspond uniquement à Cz et \mathbf{m}_6 correspond uniquement à Pz (*voir* la section 3.1 et la Figure 3.1).

4.3 Segmentation adaptative

Pour chaque montage, on crée une fonction de détection temps-fréquence à l'aide de la CWT (*voir* les sections 3.2 et 3.3) couvrant la bande 10Hz-16Hz avec une résolution de 0.1Hz. La segmentation adaptée à la fonction de détection temps-fréquence topographique génère l'ensemble $\tilde{\mathbf{X}}$ de tous les événements dans la bande des fuseaux 10Hz-16Hz qui se produisent au cours de toute la nuit sur ce montage. Considérant la moyenne à travers les montages et ensuite la moyenne à travers tous les sujets, on obtient 71826 ± 5865 événements par montage (*voir* le Tableau-A III-1 dans l'ANNEXE III pour le décompte pour tous les sujets et pour chaque montage). On peut obtenir une estimation de la durée moyenne des segments créés en divisant la durée moyenne des nuits (489.0 min, donc 29340.0 sec, *voir* plus haut) par cette quantité moyenne de segments créés. On obtient ainsi comme durée moyenne $29340.0/71826 = 408.5\text{ms}$. Pour chaque événement $\tilde{\mathbf{x}}_n$ créé, on calcule les caractéristiques tel que décrit à la section 3.5.

4.4 Sélection sensible: seuillage par *p-value*

La Figure 4.2 présente, pour tous les sujets et sur chaque montage, les distributions des caractéristiques $\tilde{\mathbf{x}}_n^{\text{amplitude}}$ et $\tilde{\mathbf{x}}_n^{\text{sigma}}$ utilisées dans la première phase de détection. Les

distributions sont calculées sur 61 points (nombre arbitraire). Les distributions des événements concordant temporellement avec les fuseaux de l'expert (ceux dont $\tilde{x}_n^{\text{expert}} = 1$, voir section 3.5) sont en rouge, les distributions des événements en stade REM (H_0) sont en noir et les distributions de tous les événements confondus sont en bleu pâle. Les événements fuseaux étant en moins grande quantité, les distributions sont plus bruitées ; pour améliorer la visualisation, elles sont donc lissées par convolution avec une fenêtre rectangulaire unitaire de trois points, à trois reprises (le noyau de convolution équivalent est $[1, 3, 6, 7, 6, 3, 1]$). Chaque distribution est normalisée par sa valeur maximale.

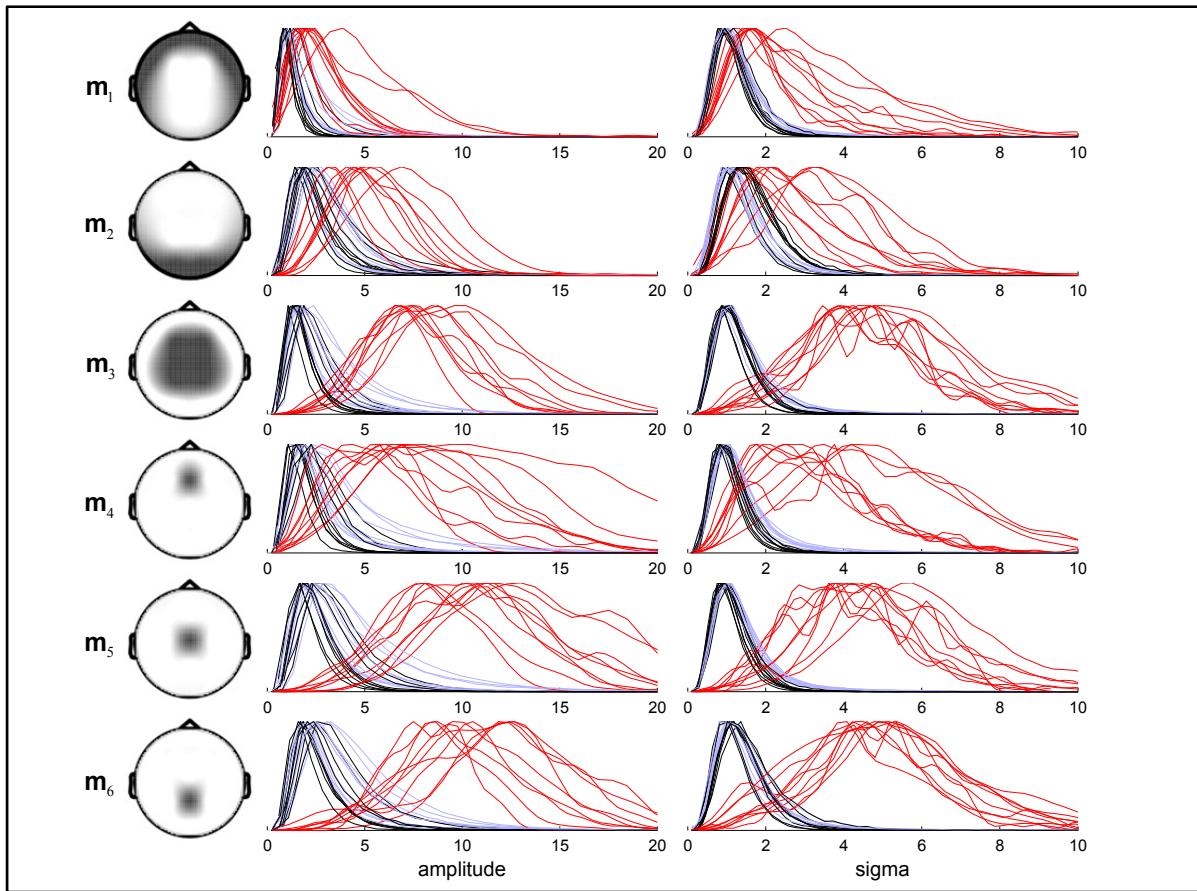


Figure 4.2 Distributions des caractéristiques utilisées dans la première phase de détection

La performance de cette phase de détection peut être anticipée par la capacité des caractéristiques à discriminer les fuseaux (en rouge) des non-fuseaux (en noir). Une forte

discrimination correspond à un faible recouvrement entre les distributions. On remarque, d'une manière générale, que le montage de détection **m**₃ discrimine pratiquement aussi bien que les montages **m**₅ (Cz) et **m**₆ (Pz). Comparativement à ces deux derniers, le montage **m**₄ (Fz) est un peu moins performant. Les montages **m**₁ et **m**₂ ont un plus faible pouvoir de discrimination. On note cependant que les fuseaux (en rouge) sont ceux détectés sur Fz, Cz et Pz; les évènements concordant temporellement sur **m**₁ et **m**₂ peuvent ne pas correspondre à des fuseaux, expliquant cette faible discrimination.

On remarque que l'amplitude moyenne des fuseaux vus sur le montage **m**₃ est légèrement plus faible que celles vues sur les électrodes Cz (**m**₅) et Pz (**m**₆). Ceci peut être du à l'effet de moyennage spatial causé par l'inclusion de neuf électrodes dans le montage **m**₃. Cet effet n'est pas observé sur la caractéristique sigma. Pour la suite du travail, seul le montage **m**₃ sera considéré.

Les évènements dont les deux caractéristiques franchissent leur seuil obtenu par p sont identifiés par une caractéristique $\tilde{X}_n^{candidat}$ à l'état *vrai* (1). À partir de cette sélection $\tilde{X}_n^{sélection} = \tilde{X}_n^{candidat}$ et des évènements de l'expert identifiés par \tilde{X}_n^{expert} , on classe chaque évènement en un de ces quatre types : VP, VN, FP, FN (*voir* la section 3.9). Le décompte de ces cas donne respectivement les quantités N_{VP} , N_{VN} , N_{FP} et N_{FN} . Ces quantités, obtenues pour un p donné, permettent de mesurer la performance en termes de sensibilité (*Se*) et de différentes formes de spécificité (*FPr*, *FPa*, *FAr* et *FPr*) (*voir* section 2.5).

Une analyse ROC consiste à analyser l'évolution de la performance de détection pour différentes valeurs p . Ainsi, on calcule les quantités *Se*, *FPr*, *FPa*, *FAr* et *FPr* pour des valeurs de p couvrant toutes les puissances de deux de -10 à 0 par bond de 0.5, résultant en 22 valeurs. La Figure 4.3 A montre une section des courbes *Se*, *Sp* et *FAr* en fonction des valeurs p .

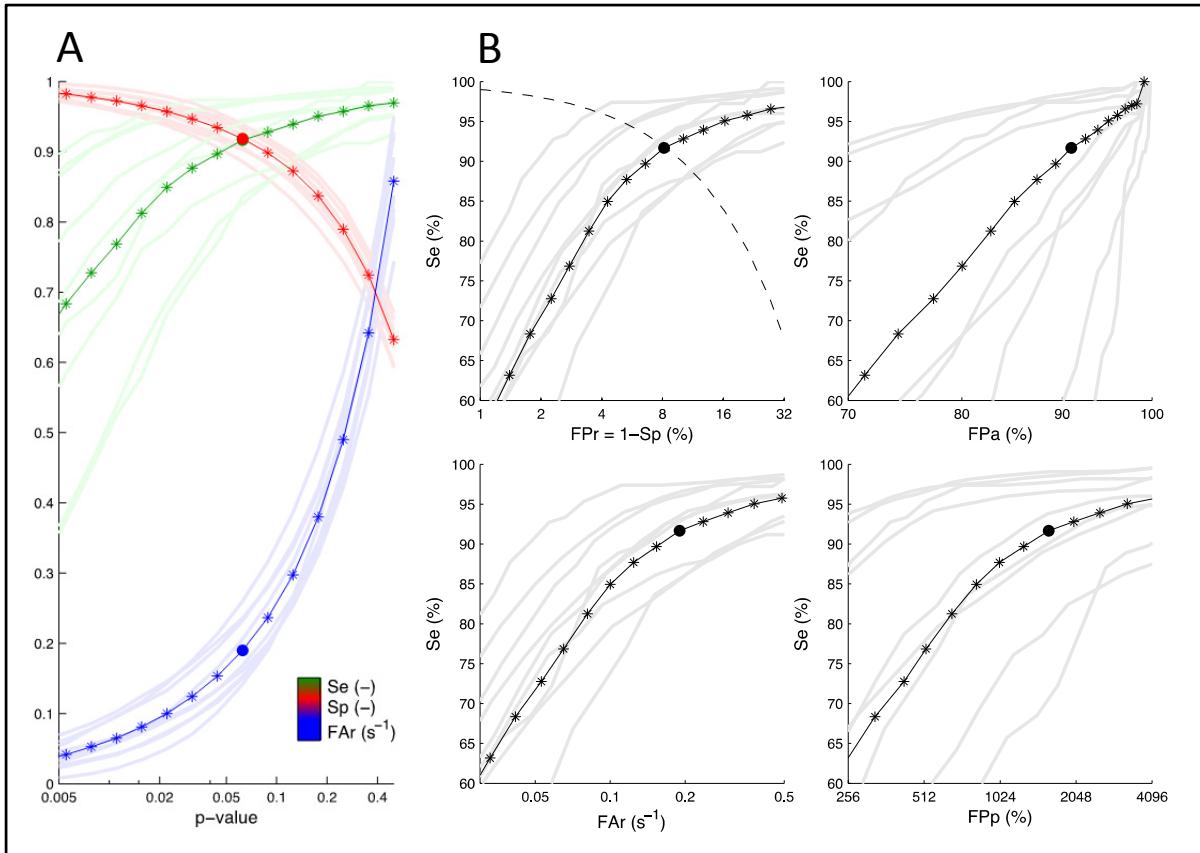


Figure 4.3 Performance en première phase de détection

A: Se (vert), Sp (rouge) et FAr (bleu) obtenus pour chaque p -value fixée. B: courbes ROC pour quatre différentes formes de spécificité (FPr , FPa , FAr et FPp). Les ronds pleins correspondent aux points optimaux ($Se = Sp$). Les abscisses sont sur une échelle logarithmique

En traçant la sensibilité Se en fonction d'une des formes de spécificité (FPr , FPa , FAr ou FPp) pour toutes les valeurs p , on obtient la courbe ROC (de l'anglais *Receiver Operating Chararcteristic*). Cette façon de présenter la performance de détection de fuseaux est utilisée dans la littérature (Babadi et al., 2012; Devuyst et al., 2011; Huupponen et al., 2007; Huupponen et al., 2000a). La Figure 4.3 B montre ces courbes ROC pour quatre mesures de spécificité (FPr , FPa , FAr et FPp , de gauche à droite et de haut en bas). Dans chaque graphique, chaque courbe de couleur pastel représente un sujet particulier. Les courbes de couleur foncée résultent de la moyenne à travers les sujets. Les astérisques (*) représentent les points pour une valeur p particulière.

Les ronds pleins représentent les points de performance *optimale*. On définit ce régime optimal comme étant le point théorique où la sensibilité et la spécificité sont égales : $Se = Sp = 1-FPr$. On considère cette optimalité dans ce sens qu'un certain compromis est atteint entre sensibilité et spécificité. En d'autres termes, le détecteur est aussi performant à identifier les positifs (fuseaux) qu'à identifier les négatifs (non-fuseaux). La ligne discontinue dans la Figure 4.3 B représente les points où $Se = 1-FPr$. Les points optimaux illustrés correspondent donc aux points de mesures les plus près de ce régime, et ce pour les courbes résultant de la moyenne de tous les sujets. À ces points, on obtient en moyenne $Se = 92.1\% \pm 3.0\%$, $FPr = 7.9\% \pm 2.7\%$, $FPa = 89.1\% \pm 8.3\%$, $FAr = 0.184 \text{ s}^{-1} \pm 0.61 \text{ s}^{-1}$ et $FPp = 1779.6\% \pm 1936.6\%$. Les valeurs des points optimaux pour chaque sujet sont compilées dans le Tableau-A IV-1 de l'ANNEXE IV.

Ces résultats montrent la performance donnant un compromis optimal en sensibilité et spécificité que l'on peut obtenir à la phase de sélection par *p-value*. Or, puisqu'on veut un régime très sensible à cette étape, on fixe la *p-value* à $p = 0.1$ pour la suite (sur la Figure 4.3 A, on se situe à droite du point optimal, dans le régime sensible). On obtient ainsi en moyenne $Se = 93.2\% \pm 4.8\%$, $FPr = 11.0\% \pm 2.1\%$, $FPa = 93.0\% \pm 4.2\%$, $FAr = 0.256 \text{ s}^{-1} \pm 0.048 \text{ s}^{-1}$ et $FPp = 2177.1\% \pm 2110.3\%$ (les valeurs pour chaque sujet sont compilées dans le Tableau-A IV-2 de l'ANNEXE IV). Cet ensemble \mathbf{X} d'événements sélectionnés correspond au sous-ensemble de $\tilde{\mathbf{X}}$ dont la caractéristique $\tilde{x}_n^{\text{candidat}}$ est à l'état *vrai* (1).

4.5 Sélection spécifique: classification hiérarchique

La deuxième phase de détection consiste à faire une classification ascendante hiérarchique (CAH) de \mathbf{X} sur les caractéristiques $x_n^{\text{fréquence}}$ et $x_n^{\text{médian}}$ tel que décrit à la section 3.7.

L'attribution des numéros de classe (caractéristique x_n^{classe}) respecte l'ordre des classes contenant le plus d'événements expert ($x_n^{\text{expert}} = 1$). La Figure 4.4 A montre la distribution des événements à travers les classes : en noir, la quantité d'événements au total et en vert, la quantité d'événements $x_n^{\text{expert}} = 1$. Dans les deux cas, le *compte* correspond à la fraction du

nombre total, toutes classes confondues. Chaque courbe en pâle correspond à un sujet et les courbes foncées correspondent à la médiane de tous les sujets.

Les événements sélectionnés sont ceux appartenant aux classes qui regroupent au moins 80% des événements $x_n^{\text{expert}} = 1$ (on utilise ici tous les fuseaux de l'expert). Cette sélection consiste en une caractéristique $x_n^{\text{classe-expert}}$ à l'état *vrai* (1). La Figure 4.4 B compare la performance obtenue avant et après la CAH. Les barres noires correspondent à la performance obtenue à la première phase de détection (en fixant $p = 0.1$) et les barres blanches à celle obtenue à la deuxième phase de détection.

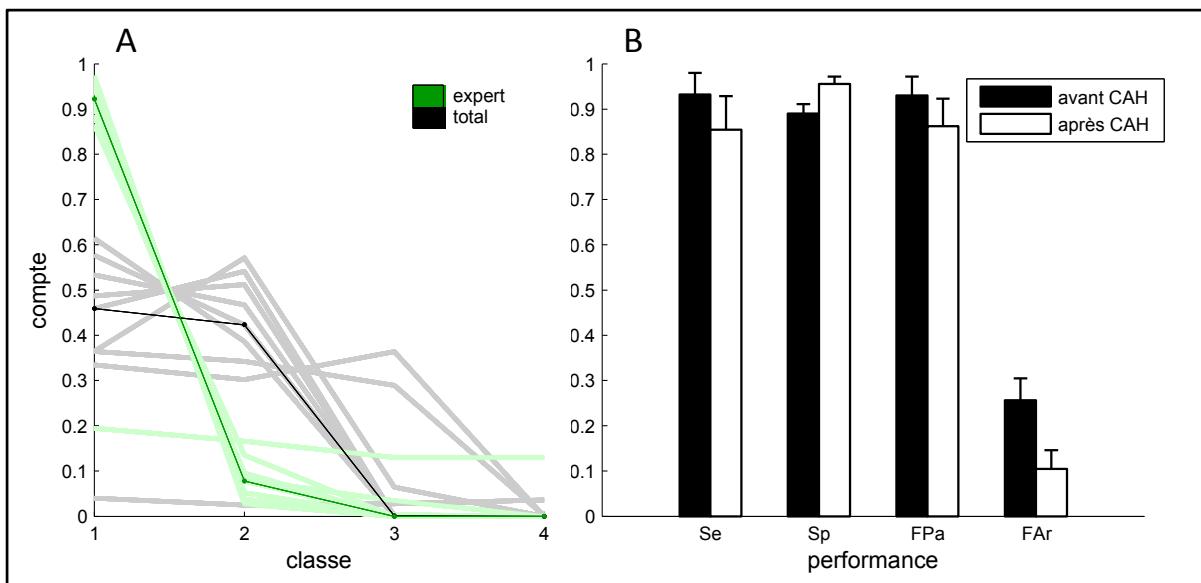


Figure 4.4 Résultats de classification ascendante hiérarchique (CAH)
A: Distribution des événements à travers les classes. B: Mesures de performance à la première phase de détection en noir (avant classification) et à la deuxième phase de détection en blanc (après classification)

On observe dans la Figure 4.4 A que pour la majorité des sujets, une seule classe suffit pour regrouper plus de 80% des événements experts. De plus, cette classe ne comporte qu'environ 50% de tous les événements sélectionnés. La seule exception est le sujet 4 qui montre une distribution uniforme à travers les classes. La sélection de cette classe *expert* permet ainsi de

rejeter la moitié des FP sans perdre significativement de VP, résultant en une augmentation significative de la spécificité Sp . La FAr , directement proportionnelle au nombre de FP, diminue de plus de la moitié en moyenne. La FPr reste toutefois relativement élevée et indique que plus de 80% des évènements sélectionnés sont des FP, i.e. des évènements non-marqués par un expert. En somme, on obtient en moyenne $Se = 85.4\% \pm 7.4\%$, $FPr = 4.5\% \pm 1.7\%$, $FPa = 86.2\% \pm 6.1\%$, $FAr = 0.105 \text{ s}^{-1} \pm 0.041 \text{ s}^{-1}$ et $FPr = 730.3\% \pm 598.9\%$ (les valeurs pour chaque sujet sont compilées dans le Tableau-A IV-3 de l'ANNEXE IV).

4.5.1 Quelle est l'importance du nombre de fuseaux identifiés par l'expert?

Les résultats précédents sont ceux obtenus en considérant tous les fuseaux marqués par l'expert, issus donc d'un marquage visuel exhaustif. On étudie ici l'effet de la quantité de fuseaux identifiés par l'expert pour la sélection supervisée des classes sur la performance de détection. Pour ce faire, on mesure la variation des mesures de performance obtenues avec un marquage partiel par rapport à celles obtenues avec un marquage exhaustif, correspondant aux résultats montrés précédemment. On considère donc des marquages partiels correspondant à la sélection d'un sous-ensemble de tous les fuseaux marqués par l'expert. On rappelle, comme on l'a vu plus haut, qu'on a en moyenne 390 fuseaux par sujet identifiés exhaustivement par l'expert (*voir également le Tableau-A II-2 de l'ANNEXE II*).

Afin d'estimer la performance obtenue pour un marquage partiel des fuseaux par l'expert, on moyenne sur 500 essais la performance obtenue d'une sélection aléatoire de Ne évènements parmi tous les évènements marqués exhaustivement par l'expert (ceux dont $\tilde{x}_n^{\text{expert}} = 1$). Ne correspond à la quantité d'évènements du marquage partiel: 1, 2, 4, 8, 16, 32, 64 ou 128. Le différentiel de performance correspond à la performance atteinte à l'aide d'un marquage exhaustif soustraite de la performance atteinte à l'aide d'un marquage partiel.

La Figure 4.5 montre les différentiels de performance (partiel - exhaustif) obtenus en fonction de Ne (quantité de fuseaux marqués par l'expert). Les barres pleines et les barres d'erreur représentent respectivement les moyennes et les écarts-types à travers les sujets. La

sensibilité Se est en vert, la spécificité Sp est en rouge et le taux de FP FAr est en bleu. Un sujet (S4) a été exclu de l'analyse. Pour ce dernier, la classification hiérarchique a généré plusieurs petites classes de tailles similaires plutôt que deux ou trois classes dominantes comme la majorité des autres sujets (*voir Figure 4.4 A*), rendant la sélection supervisée des classes très sensible au nombre d'évènements fournis par l'expert. L'observation des courbes individuelles des différentiels de performance de chaque sujet a confirmé la similitude des courbes de tous les sujets à l'exception de S4, justifiant son exclusion.

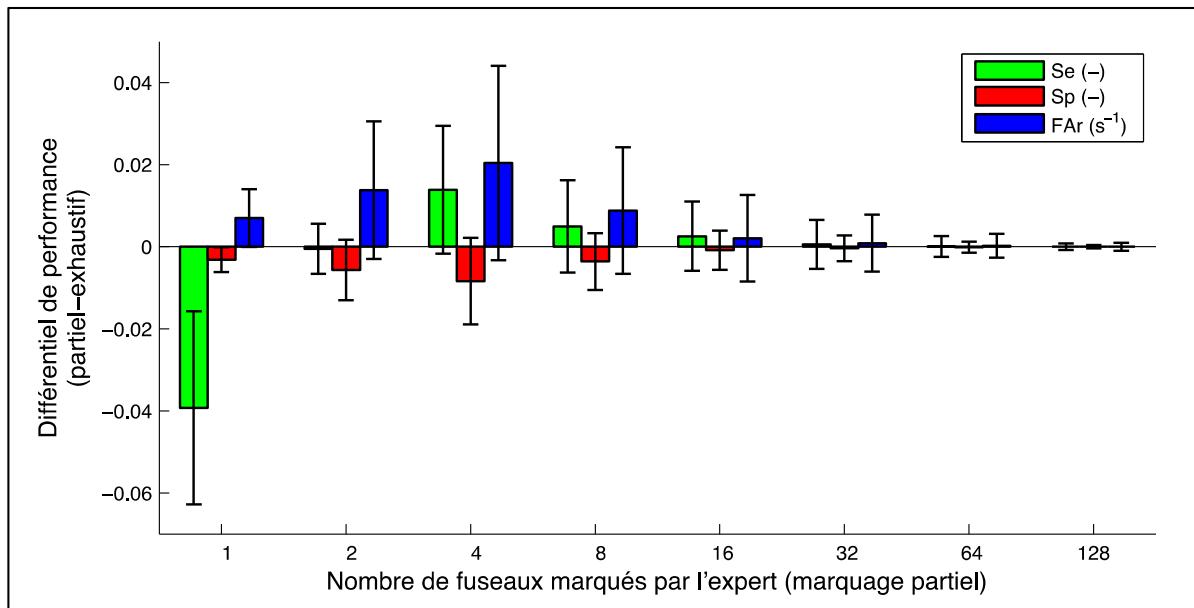


Figure 4.5 Différentiel des mesures de performance pour un marquage partiel, par rapport à un marquage exhaustif, en fonction du nombre de fuseaux marqués par l'expert

On observe qu'en identifiant deux fuseaux ou moins, la performance est dégradée par rapport à un marquage exhaustif. En effet, en marquant un seul fuseau, la spécificité diminue, le nombre de FP augmente et la sensibilité diminue significativement. En marquant deux fuseaux, la sensibilité n'est pas touchée, mais la spécificité diminue et les FP augmentent. À partir de quatre fuseaux marqués, on atteint un certain compromis sur les effets; la spécificité diminue significativement, mais la sensibilité augmente significativement de manière compensatrice. Ces effets complémentaires sont maintenus, mais d'intensité moindre, en

augmentant le nombre de fuseaux marqués, jusqu'à des effets négligeables au dessus d'une trentaine de fuseaux. On considère que les effets deviennent peu significatifs entre 16 et 32 évènements. On déduit qu'au moins une vingtaine de fuseaux marqués par l'expert sont nécessaires afin d'avoir une performance similaire à celle obtenue avec un marquage exhaustif.

4.6 Caractéristiques des fuseaux détectés

Dans cette section, on représente pour tous les sujets les fuseaux détectés et on les compare aux fuseaux identifiés par l'expert.

4.6.1 Fréquence et position médiane

La Figure 4.6 montre les distributions jointes des caractéristiques $x_n^{\text{fréquence}}$ et $x_n^{\text{médiane}}$ utilisées pour la CAH. Chaque distribution est calculée sur 61 points dans la dimension de la fréquence (de 10Hz à 16Hz par bonds de 0.1Hz) et 5 points dans la dimension de la position médiane (-0.3, -0.15, 0, 0.15 et 0.3). La première colonne correspond aux évènements sélectionnés dans la phase de détection sensible (l'ensemble **X**). La deuxième colonne correspond aux évènements concordant avec ceux d'un expert ($x_n^{\text{expert}} = 1$). La troisième colonne correspond aux évènements détectés à la phase de sélection spécifique, i.e. ceux se trouvant dans la classe regroupant la majorité des évènements de l'expert ($x_n^{\text{classe-expert}} = 1$). Les couleurs froides (vers le bleu) représentent peu d'évènements et les couleurs chaudes (vers le rouge) représentent beaucoup d'évènements. Chaque ligne de graphes correspond à un sujet (S1 à S9).

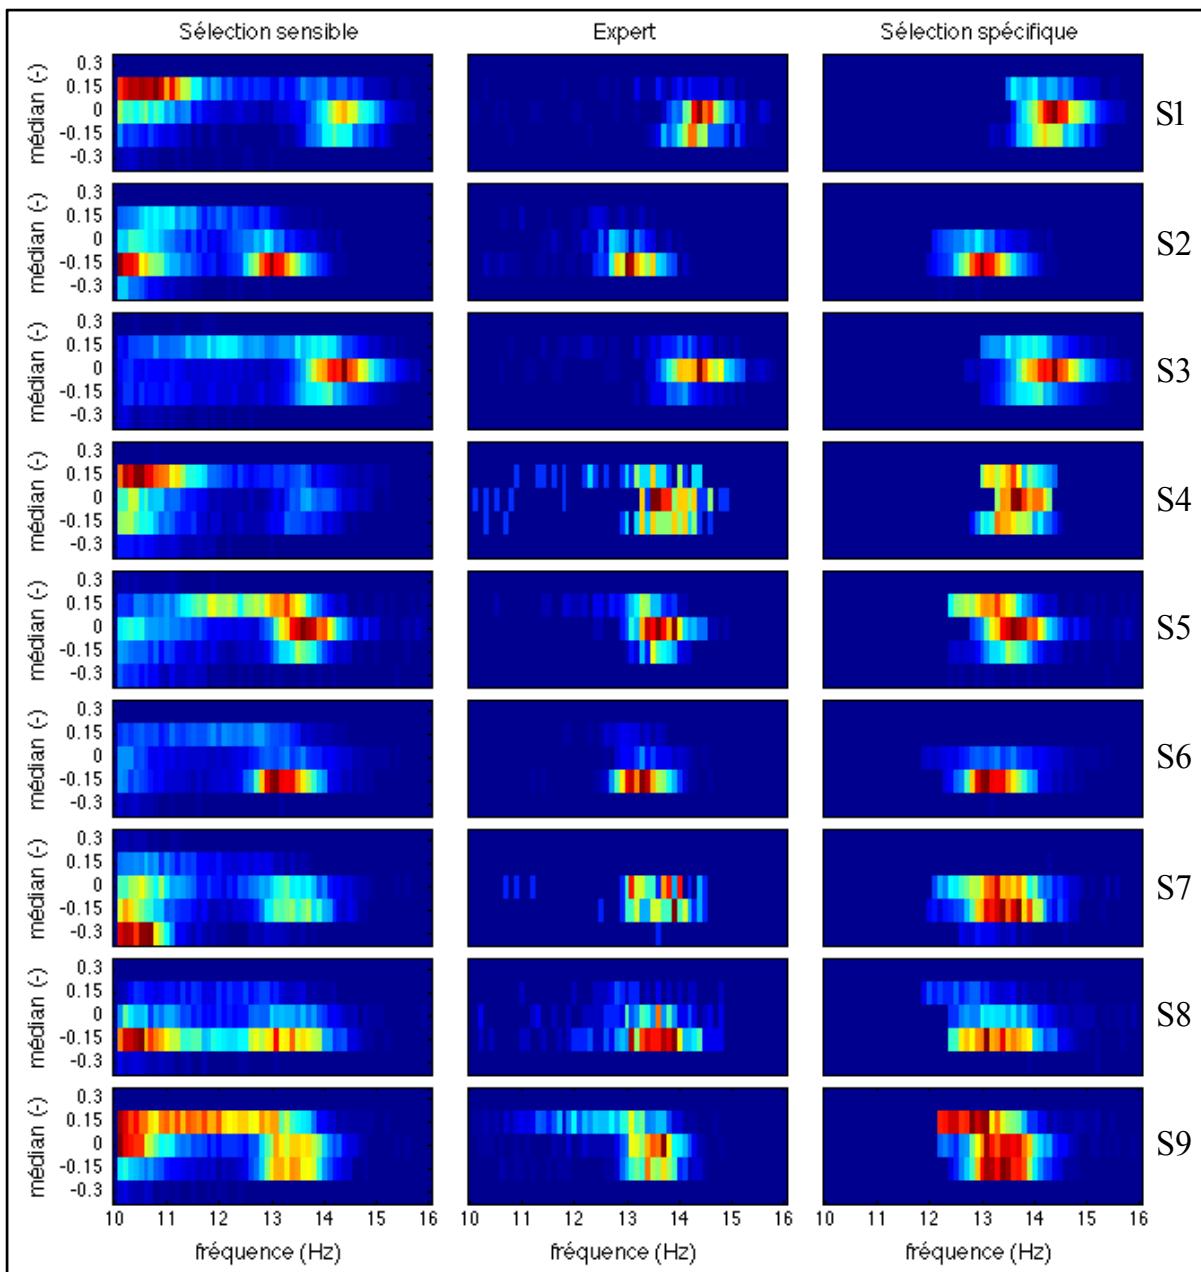


Figure 4.6 Distributions jointes des caractéristiques de fréquence et de position médiane pour tous les sujets (S1 à S9)

En général, les distributions correspondant à la première phase de détection (avant CAH, première colonne de la Figure 4.6) suggèrent la présence de deux classes. Cependant, la frontière séparant ces classes varie d'un sujet à l'autre et est moins claire pour certains. On

s'attendrait à trouver une classe rapide (fréquence élevée) en centro-pariétal (position médiane entre -0.15 et 0) et une autre plus lente (fréquence plus basse) en frontal (position médiane > 0). C'est le cas, de façon évidente, pour les sujets 1, 3, 4 et 9, et de façon un peu moins évidente pour les sujets 5 et 6. Pour les sujets 2 et 8, on observe une classe lente et une autre rapide, mais les deux situées en centro-pariétal. Pour le sujet 7, la classe plus lente est située en occipital (position médiane -0.3), suggérant une contamination par le rythme alpha.

De façon constante à travers tous les sujets, la majorité des événements de l'expert se retrouve dans la classe rapide centro-pariétale (deuxième colonne de la Figure 4.6). De plus, la distribution jointe de la classe sélectionnée (troisième colonne de la Figure 4.6) respecte fidèlement la distribution jointe de la classe expert dans tous les cas ; les FP de cette classe sélectionnée ont ainsi des caractéristiques spatiale et fréquentielle très similaires à celles des VP, i.e. des événements marqués par un expert.

4.6.2 Fuseaux moyens

La Figure 4.7 montre la grande moyenne à travers tous les sujets de trois classes de fuseaux. La première colonne correspond aux fuseaux experts, i.e. les événements de **X** (première phase de détection) dont $x_n^{\text{expert}} = 1$. La deuxième colonne correspond aux événements de la classe sélectionnée dans la deuxième phase de détection (ceux dont $x_n^{\text{classe-expert}} = 1$). Cette classe contient la majorité des événements concordant avec des fuseaux marqués par l'expert. La troisième colonne correspond aux événements de la classe non-sélectionnée (ceux dont $x_n^{\text{classe-expert}} = 0$), regroupant tous les autres événements. En A, on montre la moyenne des distributions jointes, normalisées en PDF, des caractéristiques $x_n^{\text{fréquence}}$ et $x_n^{\text{médian}}$.

En B, on montre la moyenne des signaux sur tous les canaux de 5 secondes d'activité centrées sur les fuseaux. La moyenne est d'abord calculée sur les fuseaux de chaque sujet; ces moyennes de chaque sujet sont ensuite moyennées sur tous les sujets. Pour la moyenne intra-sujet, chaque segment de 5 secondes est recalé par corrélation croisée dans la bande 10-

16Hz (seulement les 500ms centrales sont considérées) en prenant un fuseau arbitraire comme référence (le premier). La corrélation est calculée pour le plan (signal temporel multivarié) dans la dimension temporelle. Pour la moyenne inter-sujet, le recalage est identique. De plus, on normalise l'amplitude des signaux de chaque sujet par l'écart-type total, i.e. considérant tous les capteurs à la fois (puisque un filtre passe-bande a été appliqué sur chaque segment d'évènement au préalable, on considère les signaux centrés).

En C, on montre la première composante spatiale obtenue par une analyse en composantes principales via la décomposition en valeurs singulières (SVD). La SVD est calculée dans une fenêtre de 500ms centrée autour de la position au temps 0 de la moyenne inter-sujet. Le signal est préalablement filtré dans la bande 10-16Hz (Butterworth d'ordre 5). En D, on montre le plan temps-fréquence CWT (ondelette de Morse, paramètres $\gamma = 20$ et $\beta = 20$) de la moyenne inter-sujet, utilisant comme montage le vecteur topographique de la première composante principale obtenue en C.

Ces moyennes inter-sujets illustrent les tendances globales. Dans tous les cas, on voit que les caractéristiques de la classe sélectionnée (deuxième colonne) sont très similaires à celles des évènements de l'expert (première colonne). Pour ce qui est des distributions jointes (fréquence, position médiane) en A, on voit que la CAH génère deux classes disjointes, une étant rapide (13-14Hz) et centro-pariétale (classe sélectionnée) et l'autre étant plus lente (10-12Hz) et plus diffuse spatialement, mais tendant vers les régions frontales (classe non-sélectionnée). Cette diffusion peut être causée par la plus grande variabilité de cette classe à travers les sujets.

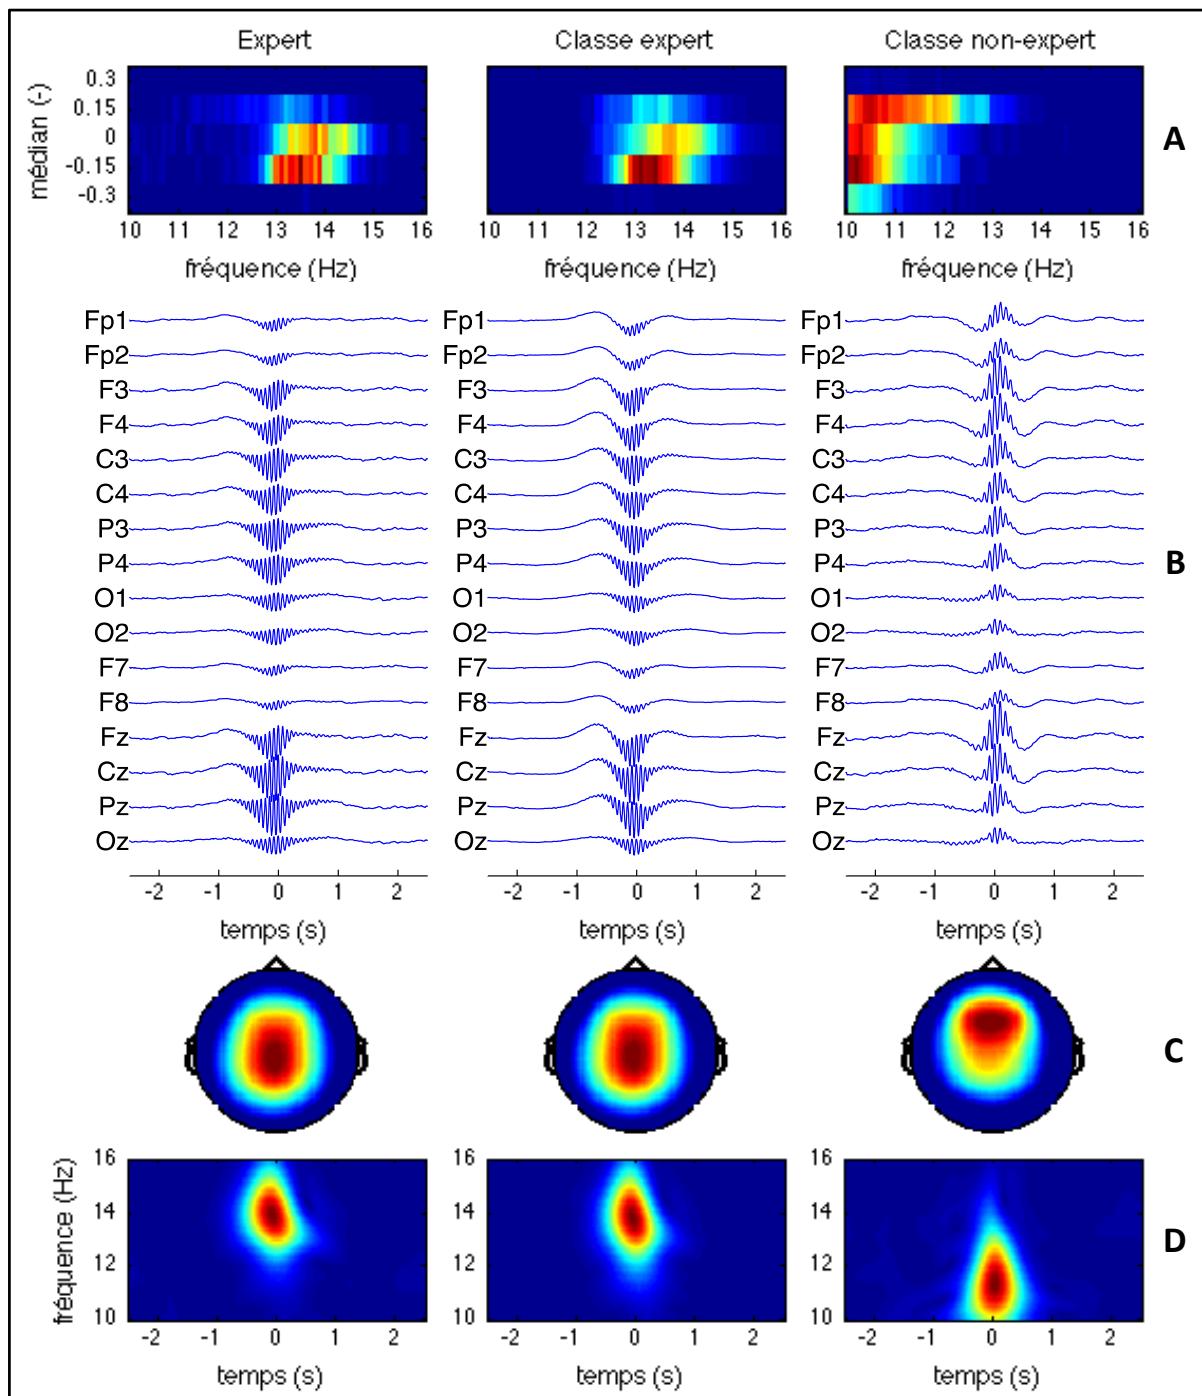


Figure 4.7 Grandes moyennes à travers les sujets

De gauche à droite : évènements expert, classe sélectionnée, classe rejetée

A: Distribution jointe de la fréquence et la position médiane. B: Signal moyen du fuseau. C: Première composante principale (spatiale) du fuseau moyen. D: Plan temps-fréquence (ondelette de Morse) du fuseau moyen, utilisant comme montage la topographie en C

Malgré la variabilité inter-sujet, il sort de la moyenne des signaux une oscillation qu'on reconnaît comme étant un fuseau (en B). Celle-ci est plus ample pour les "fuseaux experts", montrant que ces derniers tendent à être de plus grande amplitude. On remarque aussi une composante d'environ 1Hz en phase avec l'oscillation fuseau ; dans la classe rapide (et donc de l'expert), le fuseau se manifeste pendant la demi-onde négative, tandis que dans la classe plus lente, il se manifeste pendant la demi-onde positive. Cette caractéristique est observée pour la majorité des sujets.

Les topographies en C montrent explicitement que les fuseaux détectés respectent la dichotomie des fuseaux plus rapides en postérieur et ceux plus lents en antérieur. En effet, la classe plus rapide (et donc de l'expert) a son maximum en centro-pariéctal et la classe plus lente a le sien autour de Fz.

4.6.3 Quantité de fuseaux à travers les cycles de sommeil

La Figure 4.8 montre la distribution moyenne de la quantité de fuseaux à travers les quatre premiers cycles de sommeil (tous les sujets ont au moins quatre cycles) pour les évènements marqués par l'expert (à gauche), les évènements détectés de la classe spécifique de l'expert (au centre) et tous les autres évènements n'appartenant pas à la classe spécifique de l'expert (à droite). Les barres pleines représentent les moyennes à travers les sujets tandis que les barres d'erreur représentent les écart-types. Les valeurs sont normalisées; pour chaque sujet et pour chacune des trois classes considérées, l'histogramme (nombre de fuseaux pour chaque cycle) est divisé par le nombre total d'évènements dans la classe correspondante. Les distributions correspondent donc à des densités de probabilité (PDF).

Pour le découpage de la nuit en cycles de sommeil, on classe d'abord les époques de l'hypnogramme pour générer une séquence alternée de périodes NREM (stades 1, 2, 3 et 4) et REM (stade 5). Un cycle correspond à un bloc constitué d'une période NREM suivie d'une période REM. La période NREM débute dès la première époque marquée comme stade 1 et se termine dès la première époque marquée comme stade 5, ce qui débute la période REM.

La période REM se termine quand les 15 minutes suivantes ne contiennent pas d'époques marquées comme stade 5, correspondant à la fin du cycle en cours.

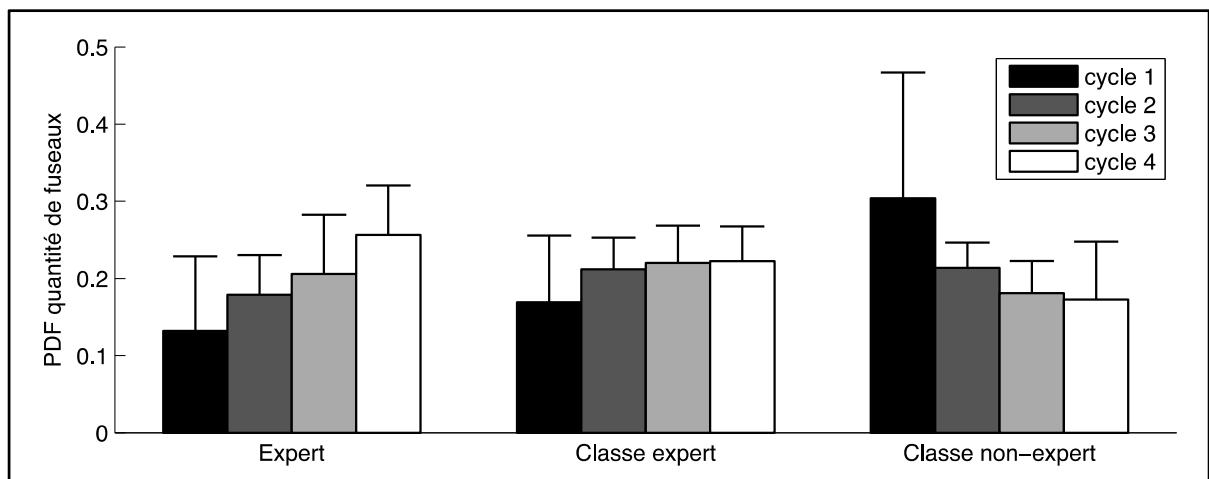


Figure 4.8 Distribution de la quantité de fuseaux à travers les cycles de sommeil

Malgré des barres d'erreur significatives, on observe des tendances différentes entre les classes sélectionnée et rejetée. La classe "expert" a une tendance similaire à la classe sélectionnée. On devait s'attendre à cette dernière observation puisque la classe sélectionnée est définie à partir des événements experts. Pour la classe rejetée (principalement de type lent-antérieur), la tendance est une décroissance de cycle en cycle. On observe une tendance opposée pour la classe sélectionnée (principalement de type rapide-postérieur), avec une croissance au cours de la nuit, avec un amortissement à partir du cycle trois, non observé pour la classe "expert".

CHAPITRE 5

DISCUSSION

Le présent travail a abordé le problème de la détection automatique des fuseaux du sommeil. On peut remonter aux années 70 pour trouver les premières formes de ces détecteurs. Depuis, plusieurs ont vu le jour en exploitant diverses méthodes issues du domaine du traitement de signal. Dans les sections 2.2 et 2.3, on a classé ces détecteurs en deux types: ceux à fonction de détection et ceux à classification. La problématique persistante à l'issue de tous ces travaux est principalement la difficulté à gérer la spécificité de détection. Le but du présent travail était de partir sur la base d'un algorithme sensible auquel on ajoute une étape de classification à des fins de spécificité.

5.1 Montage de détection

Dans un premier temps, on a défini une transformation d'un signal EEG multivarié (signaux simultanés de plusieurs capteurs) en un signal univarié représentant le décours temporel d'une topographie particulière ; en d'autres termes, on a défini un montage spécifique aux fuseaux. Basé sur la définition des fuseaux (Iber et al., 2007; Rechtschaffen et Kales, 1968) et sur les connaissances à ce jour sur l'occurrence des fuseaux sur le scalp, un montage uniforme \mathbf{m}_3 couvrant les électrodes frontales (F3, Fz et Fz), centrales (C3, Cz, C4) et pariétales (P3, Pz, P4) a été définie (*voir* section 3.1). Cette compression de l'information de l'activité sur tous les capteurs en un seul signal représente une réduction considérable de la dimension du problème de détection et de création d'événements.

Pour valider l'utilisation d'un montage *fuseau* comme outil d'analyse de données multivariées, on en a défini cinq autres à titre de comparaison: un montage pré-frontal \mathbf{m}_1 (Fp1, Fp2, F7 et F8), un montage occipital \mathbf{m}_2 (O1, O2, Oz), un montage \mathbf{m}_4 spécifique à Fz, un montage \mathbf{m}_5 spécifique à Cz et un montage \mathbf{m}_6 spécifique à Pz.

Les résultats concernant le pouvoir de discrimination entre fuseaux et non-fuseaux (*voir* Figure 4.2) sont au moins aussi bons pour \mathbf{m}_3 par rapport à \mathbf{m}_4 , \mathbf{m}_5 et \mathbf{m}_6 (considérés comme le *gold standard*) et beaucoup moins bon pour les montages \mathbf{m}_1 et \mathbf{m}_2 . Ceci valide le fait que d'utiliser ce montage ne diminue par la *sensibilité* à détecter des fuseaux. De plus, les moins bons résultats obtenus pour \mathbf{m}_1 et \mathbf{m}_2 par rapport à \mathbf{m}_3 , \mathbf{m}_4 , \mathbf{m}_5 et \mathbf{m}_6 montrent que l'utilisation d'un montage approprié apporte une *spécificité* spatiale ; en effet, on ne s'attend pas à détecter correctement, sur \mathbf{m}_1 et \mathbf{m}_2 , des fuseaux marqués par l'expert sur Fz (\mathbf{m}_4), Cz (\mathbf{m}_5) et Pz (\mathbf{m}_6).

5.2 Segmentation adaptative

Dans un deuxième temps, on a conçu une méthode de détection de tous les événements potentiellement fuseaux, i.e. toutes les oscillations dans la bande fréquentielle 10Hz-16Hz. Ceci a été réalisé en segmentant une fonction de détection selon ses extrema locaux pour créer un ensemble d'événements de durées variables se juxtaposant pour couvrir la totalité des données (*voir* section 3.4). Cette fonction de détection a été générée à partir du plan temps-fréquence calculé par CWT, couvrant la bande 10Hz-16Hz avec 0.1Hz de résolution (*voir* section 3.3).

Le choix de la CWT est motivé par le besoin d'une grande résolution fréquentielle et temporelle. Contrairement aux représentations plus compactes des ondelettes discrètes (DWT) ou des paquets d'ondelettes (WPT), les coefficients des ondelettes continues (CWT) sont très corrélés entre eux, donc redondants. C'est néanmoins cette redondance qui génère un plan temps-fréquence continu (lisse), dont la détection des maxima locaux permet une résolution temporelle et fréquentielle la plus maximale possible. Le filtrage par CWT a été réalisé avec l'ondelette de Morse. Le choix cette ondelette particulière est motivé par un compromis optimal qu'elle procure entre résolution fréquentielle et temporelle, et par sa définition relativement simple (*voir* section 3.2).

L'ondelette de Morse est paramétrée par deux quantités, γ et β , qui définissent la résolution fréquentielle (l'ordre du filtre) et la résolution temporelle (les moments nuls). Les valeurs utilisées pour ce travail sont $\gamma = 20$ et $\beta = 10$. Le paramètre le plus sensible dans le présent travail est β . Une valeur élevée a tendance à lisser les coefficients dans la dimension temporelle, augmentant en moyenne la durée des événements détectés (diminuant aussi, d'une certaine manière, la résolution temporelle). Une valeur trop faible rend l'ondelette sensible aux fluctuations du signal, diminuant en moyenne la durée des événements détectés et pouvant générer une séquence de maxima locaux attribuables à un seul événement. Ce problème est similaire à celui rencontré pour les détecteurs de type 1 (voir Figure 2.1, l'exemple du deuxième événement). La valeur $\beta = 10$, sélectionnée de manière arbitraire, pourrait nécessiter une valeur plus élevée dans des données très bruitées, par exemple lors d'acquisitions simultanées EEG et imagerie par résonance magnétique fonctionnelle (IRMf). Ainsi, il serait possible de *lisser* les interférences électromagnétiques potentiellement engendrées par l'appareil d'IRM, au coût d'une légère perte en résolution temporelle.

Enfin, cette méthode de recensement de tous les événements, ayant comme seul critère la bande fréquentielle, se révèle pratique pour appliquer des méthodes statistiques sur les caractéristiques de ceux-ci, comme cela a été réalisé dans ce travail (voir section 3.6), permettant d'adapter la détection à chaque sujet. Une spécificité inter-sujet de ce type n'est cependant possible qu'en traitement hors-ligne (*offline*), i.e. sur des enregistrements préalablement stockées en mémoire dans un ordinateur. En effet, le traitement statistique des caractéristiques est postérieur à la création de *tous* les événements. Une méthode permettant le traitement *online* des enregistrements EEG pour la détection de fuseaux pourrait être avantageuse pour d'éventuelles études ou traitements qui nécessiteraient la détection en temps réel des fuseaux.

5.3 Sélection sensible: seuillage par *p-value*

La sélection des événements considérés comme fuseaux a été faite en deux phases. La première, dite *sensible*, est basée sur les caractéristiques $\tilde{X}_n^{\text{amplitude}}$ et $\tilde{X}_n^{\text{sigma}}$ et supervisée par

l'expert via la caractéristique $\tilde{X}_n^{\text{stade}}$ (stade de sommeil). La sélection est effectuée par seuillage sur les caractéristiques à maximiser $\tilde{X}_n^{\text{amplitude}}$ et $\tilde{X}_n^{\text{sigma}}$, dont le seuil, pour chaque caractéristique, est déterminé en fixant une *p-value* sur l'hypothèse nulle (l'évènement n'est *pas* un fuseau). Cette dernière est obtenue de la distribution des valeurs pendant le stade REM. La deuxième phase de sélection, dite *spécifique*, est basée sur les caractéristiques $X_n^{\text{fréquence}}$ et $X_n^{\text{médian}}$ et supervisée par l'expert via la caractéristique X_n^{expert} (événements identifiés comme fuseau). La sélection est effectuée par classification ascendante hiérarchique (CAH) et les classes sélectionnées sont celles regroupant la majorité des évènements marqués par l'expert.

Le choix de $\tilde{X}_n^{\text{amplitude}}$ et $\tilde{X}_n^{\text{sigma}}$ est motivé par la littérature. L'amplitude est utilisée dans une majorité des détecteurs à fonction de détection (*voir* section 2.2) et a ainsi confirmé à maintes reprises sa capacité à détecter les fuseaux. Le rapport sigma est plus récent, utilisé dans les travaux de Huupponen et repris par d'autre (Devuyst et al., 2011). Cette caractéristique, validée dans ces travaux, a l'avantage de pouvoir rejeter certains artefacts, comme le bruit musculaire et le rythme alpha. L'objectif à cette étape était d'avoir des caractéristiques sensibles, maximisées chez les fuseaux. La Figure 4.2 le confirme, en montrant des distributions disjointes entre fuseaux et non-fuseaux (les montages d'intérêt étant **m**₃, **m**₄, **m**₅ et **m**₆). Les courbes ROC de performance de la Figure 4.3 B confirment davantage que ces caractéristiques permettent d'atteindre une sensibilité *Se* très élevée, de plus de 90%, avec une spécifique *Sp* satisfaisante, aussi autour de 90%.

D'autres caractéristiques semblables à l'amplitude sont utilisées dans la littérature, comme la valeur RMS ou l'énergie. Cependant, ces quantités doivent être calculées sur une période de temps couvrant l'évènement, contrairement à l'amplitude qui est une valeur ponctuelle qui ne dépend pas de la durée de l'évènement. La façon répandue de calculer ces caractéristiques d'énergie et de valeur RMS est d'utiliser une durée fixe, communément entre 0.5 et 1 seconde. Sinon, il faut calculer cette durée ; or, une définition précise du début et de la fin d'un fuseau n'existe pas et celles utilisées dans la littérature varient. C'est pour cette raison

que la durée n'a pas été considérée pour la sélection dans le présent travail. On note au passage que le rapport sigma calculé dans ce travail est obtenu de la CWT et non de la FFT ; ainsi, les valeurs à chaque fréquence sont tirées du plan temps-fréquence à un instant ponctuel, contrairement à la FFT qui nécessite une fenêtre temporelle de données. Le sigma calculé dans le présent travail ne dépend donc pas de la durée des événements.

La sélection s'est faite en fixant une *p-value* sur l'hypothèse nulle H_0 : l'évènement n'est pas un fuseau (plus précisément : la valeur observée pour cette caractéristique ne correspond pas à un fuseau). On a construit la distribution de H_0 , pour chaque caractéristique, à partir des évènements en REM. Le choix du stade REM pour H_0 est basé sur le simple fait que, de par leur définition actuelle, les fuseaux ne se manifestent pas durant ce stade. Le choix d'une bonne H_0 est important pour que la *p-value* soit cohérente. Dans ce travail, le stade REM était disponible, car on avait des nuits complètes. Pour d'autres protocoles, par exemple sur des données de sieste, il est moins probable que des périodes REM soient disponibles. Dans ce cas, H_0 pourrait être alternativement construite sur des périodes d'éveil ou d'autres identifiées par un expert comme ne contenant pas de fuseaux.

La Figure 4.3 A suggèrent que, étant donnée H_0 , des seuils définis par une *p-value* $p \approx 0.06$ donnent une performance optimale, qu'on considère comme un point où $Sp = Se$. Cependant, les mesures alternatives de spécificité (FAr , FPa , FPp , voir Figure 4.3 B) rappellent que la quantité de FP (événements sélectionnés par le détecteur et non marqués par l'expert) à ce point optimal reste très élevé, malgré une spécificité Sp satisfaisante (environ 90%). De par la définition de Sp , on comprend qu'une spécificité élevée est atteignable quand il y a beaucoup de VN par rapport au FP, ce qui est le cas pour des nuits complètes. Par contre, $FPa = 90\%$ signifie que 9 évènements sur 10 identifiés par le détecteur est un FP, $FPp = 1500\%$ signifie qu'il y a 15 fois plus de FP que d'évènements marqués par l'expert ($FN+VP$) et $FAr = 0.2$ signifie qu'il y a en moyenne 2 FP par segment de 10 secondes (voir les définitions à la section 2.5).

5.4 Sélection spécifique: classification hiérarchique

Les taux élevés de FP ont confirmé le besoin d'une deuxième phase de sélection. Pour celle-ci, on a choisi une valeur $p = 0.1$ pour s'assurer d'avoir une performance en général dans le régime sensible ($Se > Sp$). Cette sélection a consisté en la CAH sur les caractéristiques $x_n^{\text{fréquence}}$ et $x_n^{\text{médian}}$ des évènements sélectionnés à la première phase (*voir* section 3.7). Le choix de ces caractéristiques a été motivé par l'accumulation de preuves qu'il y aurait deux types de fuseaux : des fuseaux plus rapides sur les dérivations centro-pariétales et des fuseaux plus lents sur les dérivations frontales. Ces caractéristiques étaient donc adaptées à mettre en lumière cette structure spatio-fréquentielle. Ainsi, en sélectionnant un sous-ensemble de classes regroupant une majorité d'évènements marqués par un expert (identifiés par la caractéristique x_n^{expert}), on pouvait sélectionner les évènements respectant une telle structure spatio-fréquentielle spécifique aux fuseaux.

Le choix de la CAH comme méthode de classification est motivé par sa nature non-supervisée, contrairement aux réseaux de neurones artificiels (ANN) et aux *Support Vector Machines* (SVM) qui nécessitent d'être entraînés sur une base de données (*voir* section 2.3.3). Une autre méthode très courante de classification non-supervisée est le *k-means* mais, pour celle-ci, il faut spécifier le nombre de classes, qui est inconnu. De plus, la classification finale est très sensible aux conditions initiales, i.e. les centroïdes initiaux. La CAH ne résout pas le problème du nombre de classes. Elle construit d'abord la hiérarchie complète (qui peut être visualisée sous la forme d'un dendrogramme, *voir* Figure 3.8) ; la classification finale consiste à *couper* cet arbre à un certain endroit. Plusieurs solutions existent, dont certaines se basent sur un degré d'homogénéité intra-classe ; pour le présent travail, un critère basé sur l'homogénéité dans la taille des classes a été utilisé (*voir* section 3.7).

La CAH dépend de la métrique utilisée, i.e. la mesure de distance $d(n,m)$ entre les points. La distance euclidienne a été choisie, car elle est simple, répandue, et des essais avec d'autres métriques n'ont pas donné de meilleurs résultats. Pour qu'elle soit valide, les dimensions des points, i.e. les caractéristiques des évènements, doivent être de même nature ; ce n'est pas le

cas avec la fréquence et la position médiane. Les caractéristiques ont donc été normalisées en leur soustrayant leur valeur minimale et divisant par l'étalement (différence entre les valeurs maximale et minimale). Ainsi, elles perdent leurs unités physiques et la forme de leur distribution reste la même, mais avec un minimum à 0 et un maximum à 1.

La métrique de liaison interclasse $L(\mathbf{A}, \mathbf{B})$ choisie a été la moyenne des distances $d(a, b)$ entre toutes les paires d'éléments des deux classes **A** et **B**. Cette métrique est connue sous le sigle UPGMA. Encore une fois, d'autres métriques sont possibles, dont les plus communes sont la liaison minimum *single link* ($L(\mathbf{A}, \mathbf{B})$ est la distance *minimale*, contrairement à la moyenne), la liaison maximum *complete link* ($L(\mathbf{A}, \mathbf{B})$ est la distance *maximale*, contrairement à la moyenne) et la liaison de Ward ($L(\mathbf{A}, \mathbf{B})$ est basée sur la variance des distances). La liaison minimum groupe deux classes du moment qu'au moins deux de leurs points respectifs sont proches, ce qui fait qu'elle est très sensible au phénomène d'enchainement (*chaining*), où les points tendent à se grouper à une classe déjà existante plutôt que de former une nouvelle classe. Elle est néanmoins robuste par rapport aux données aberrantes. Les liaisons de Ward et maximale tendent à former des classes d'égales grandeurs, les rendant sensibles aux données aberrantes. Le choix de la liaison moyenne a été motivé par le compromis qu'elle procure comparativement aux autres (Timm, 2002).

Les résultats obtenus montrent que les choix de métrique sont justifiés en général ; dans la majorité des cas, la CAH a généré deux classes principales (rapide et lente), comme on s'y attendait (voir Figure 4.4 A, Figure 4.6). On observe cependant un cas d'enchainement pour un sujet (sujet 4), observable par la génération d'une grande quantité de classes de petite taille, malgré le fait qu'on devine deux classes principales sur la distribution jointes de la Figure 4.6 (première colonne, quatrième ligne). La raison de cet enchainement peut être que le groupe plus rapide est inférieur en nombre par rapport au groupe plus lent ; le groupe lent dominant aurait tendance à intégrer les événements plus rapides petit à petit lors de l'agglomération. Ainsi, les événements experts sont diffusés sur plusieurs petites classes, comme observé à la Figure 4.4 A. Dans ce cas particulier, la liaison maximale ou de Ward pourrait éviter ce phénomène indésirable.

5.5 Caractéristiques des fuseaux détectés

De manière reproductible sur tous les sujets, la majorité des événements de l'expert s'est retrouvée dans la classe rapide centro-pariétale. Ce n'était pas un résultat attendu, puisque si la dichotomie des fuseaux rapides-postérieurs et lents-antérieurs est bien réelle, on s'attendrait à ce que l'expert identifie autant de fuseaux d'une classe que de l'autre. On est tenté de mettre en lien ce résultat avec le fait que l'émergence de cette dichotomie a été principalement issue de travaux utilisant des détecteurs automatiques. Ainsi, l'œil de l'expert pourrait être davantage sensible aux oscillations plus rapides, malgré la faible différence de fréquence entre les deux types (environ 1-2Hz). En effet, même les fuseaux détectés sur Fz se retrouvent dans cette classe rapide-postérieure, ce qui implique qu'en général, un fuseau identifié en Fz serait un événement plus rapide et fort en Cz-Pz, mais assez diffus pour être vu en Fz. On doit cependant attribuer ce résultat à l'unique expert impliqué dans ce travail; il est possible qu'un autre expert ait une tendance à marquer autant de fuseaux pour les deux classes. La reproduction de ce résultat avec d'autres experts aurait néanmoins des implications dans l'interprétation des résultats des détecteurs automatiques.

Cette tendance des fuseaux de l'expert de se regrouper dans une même classe a permis d'augmenter significativement la spécificité avec la CAH, en comparaison avec la spécificité atteinte avant la CAH (*voir* Figure 4.4 B). En effet, puisque les deux principales classes (rapide-postérieure et lente-antérieure) sont de tailles sensiblement égales (*voir* Figure 4.4 A), la sélection spécifique de la classe rapide-postérieure retient en moyenne plus de 90% des événements de l'expert et environ 50% des FP, augmentant les mesures de spécificité sans trop atteindre la sensibilité. Le taux de FP reste toutefois élevé, avec $FPa \approx 85\%$ en moyenne, signifiant que plus de 8 événements sur 10 sélectionnés par le détecteur est un FP.

Cependant, à l'issue des deux phases de sélection, ces FP ont répondu à des critères typiques des fuseaux (amplitude et index sigma) en plus de respecter la structure spatio-fréquentielle d'événements marqués par un expert, qui commence aussi à être reconnue comme typique des fuseaux. Ceci amène à questionner la raison d'un nombre aussi élevé de tels événements

additionnels (identifiés par le détecteur et non marqués par l'expert) qu'on identifie comme FP. Cette surabondance est typique de tous les détecteurs automatiques et a été une des motivations de ce travail. Il est possible qu'une partie significative de ces FP soient de *vrais* fuseaux, mais plus subtils, qui échapperait à l'œil humain d'un expert; dans ce cas, le fuseau serait un phénomène fréquent pendant le sommeil NREM, peut-être même la manifestation d'une activité rythmique continue d'intensité sporadique. Une manière d'obtenir une partie de réponse serait de présenter des exemplaires de FP à l'expert, qui pourrait revenir sur sa décision pour certains d'entre eux et ainsi donner une indication sur la sensibilité réellement supérieure du détecteur automatique. De montrer aussi, de manière aveugle et aléatoire, des exemplaires de VN pourrait contrôler pour le biais engendré par le fait que l'expert saurait qu'on lui présente des événements potentiellement fuseaux. Enfin, il est aussi possible que la définition actuelle des fuseaux ne soit pas assez spécifique pour les détecteurs automatiques; la propriété *gesltaltique* resterait pour le moment inatteignable. Dans tous les cas, il restera toujours une partie de ces FP qui ne sont réellement pas des fuseaux.

Les fuseaux moyens présentés à la Figure 4.7 montrent que, globalement, le détecteur sélectionne des événements de manière cohérente avec ce que l'on connaît des fuseaux : une oscillation durant environ 0.5-1 seconde et une dichotomie de fuseaux rapides-postérieurs (entre 13Hz et 14Hz, centro-pariéctal) et lents-antérieurs (autour de 11Hz, frontal). Ces grandes moyennes ignorent cependant la variabilité inter-événements et inter-sujets. Néanmoins, l'observation des moyennes individuelles de chaque sujet a suggérée que la grande moyenne est représentative de tous les sujets. Le résultat le plus inattendu est la persistance, à travers le moyennage, d'une composante d'environ 1Hz associée à l'oscillation du fuseau. Le fuseau rapide-postérieur se manifeste durant la demi-onde négative tandis que le fuseau lent-antérieur se manifeste durant la demi-onde positive.

Cette dernière observation, bien qu'à ne pas prendre comme un résultat, suggère tout de même de concentrer les efforts futurs sur la prise en compte de l'interaction de l'oscillation fuseau avec les autres bandes de fréquences pour la prochaine génération de détecteurs

automatiques. Le couplage temporel du fuseau avec une oscillation lente, entre 0.5Hz et 4Hz, a déjà été proposé (Molle et al., 2011; Molle et al., 2002). Un autre travail a étudié le groupement d'oscillations *gamma* (30Hz-100Hz) par l'oscillation fuseau (Ayoub et al., 2012). L'intégration de cette structure temporelle sous forme de nouvelles caractéristiques (par exemple, la phase des oscillations basse et haute fréquences) pourrait définir plus complètement les fuseaux et augmenter la spécificité dans la détection automatique.

La distribution des fuseaux détectés à travers les quatre premiers cycles de sommeil est présentée à la Figure 4.8. La classe de fuseaux sélectionnés, principalement de fréquence rapide et localisée en postérieure, montre un profil semblable à celui de la classe des événements concordant avec des fuseaux de l'expert, avec une augmentation progressive à travers les cycles. On pouvait s'attendre à ce résultat étant donné que les fuseaux de l'expert ont servi à choisir la classe sélectionnée. Cependant, les classes ne sont comparables qu'en termes de fréquence et de position spatiale; rien ne motive *a priori* une similitude en termes de quantité d'événements à travers les cycles. Ce profil similaire supporte donc davantage le fait que les événements de la classe sélectionnée ont spécifiquement des caractéristiques de fuseaux. De plus, ce profil concorde avec celui, connu, de la densité de fuseaux dans la bande sigma 12Hz-14.75Hz (De Gennaro et Ferrara, 2003).

Les événements de la classe non-sélectionnée, majoritairement de basse fréquence et localisée en antérieur, ont un profil différent, montrant une diminution progressive à travers les cycles. Il est connu que la puissance dans la bande delta (0.5Hz-4.75Hz) montre ce profil (De Gennaro et Ferrara, 2003). Il serait ainsi possible que les événements de cette classe spécifique soient en lien étroit avec l'activité à très basse fréquence durant le sommeil lent.

5.6 Rôle de l'expert

La méthodologie de détection proposée est semi-automatique, car elle nécessite un apport d'information de la part d'un expert. Celui-ci intervient à deux reprises et ce pour chaque sujet: génération d'un hypnogramme (contenant les stades de sommeil) et identification de

quelques fuseaux. Les stades de sommeil (en particulier le stade REM) sont utilisés pour la définition des seuils statistiques à l'étape de sélection sensible (*voir* section 3.6). Les fuseaux marqués servent à la sélection supervisée des classes générées par une classification hiérarchique non-supervisée à l'étape de sélection spécifique (*voir* section 3.7).

La tâche de génération de l'hypnogramme ne doit pas être considérée comme un désavantage de la méthode en termes d'effort et de complexité. En effet, l'identification des stades est une pratique établie et nécessaire à l'étude de données du sommeil. De plus, c'est une tâche relativement rapide pour un expert, puisque la classification est conventionnellement effectuée sur des segments de 20 ou 30 secondes. Pour la méthodologie proposée, la tâche pourrait être allégée en ne demandant à l'expert d'identifier que quelques segments correspondant à du sommeil REM ou, plus directement, quelques segments ne contenant aucune activité de fuseau. Une façon de s'abstraire totalement de l'expert pour cette tâche serait d'utiliser un détecteur automatique des stades de sommeil, solution qui existe dans la littérature (Anderer et al., 2005).

La tâche d'identification de quelques fuseaux sert à gagner en spécificité en sélectionnant de manière supervisée les classes spécifiquement fuseaux à la deuxième étape de sélection. Les résultats ont montré que cette approche permettait une telle amélioration de la spécificité (*voir* section 4.5 et Figure 4.4). L'intérêt de ce rôle de l'expert pour cette étape dépend de la quantité de fuseaux qu'il doit identifier. En effet, si le marquage doit être exhaustif ou presque (plus de 100 fuseaux identifiés par sujet), la méthodologie de détection automatique perd son avantage par rapport à la détection visuelle. L'effet du nombre de fuseaux marqués par l'expert sur la performance de détection a été étudié à la section 4.5.1. Les résultats, présentés à la Figure 4.5, montrent que la performance de détection pour un marquage partiel (par rapport à un marquage exhaustif) est dégradée en identifiant deux fuseaux ou moins, qu'on perd en spécificité (compensée par un gain en sensibilité) avec quatre fuseaux ou plus, et que le différentiel de performance devient négligeable à partir d'une trentaine de fuseaux. De plus, on considère qu'à partir d'une vingtaine de fuseaux, le différentiel devient peu

significatif. Le marquage de seulement vingt fuseaux par sujet, tâche relativement rapide pour un expert, justifie l'intérêt de la méthodologie.

Afin de s'abstraire de l'expert pour cette tâche, il faudrait sélectionner automatiquement les classes à l'étape de sélection spécifique. Comme les résultats l'ont montré (*voir* la Figure 4.6 et la Figure 4.7), la méthodologie de détection proposée permet de séparer efficacement les classes d'évènements sur les critères de fréquence et de position médiane. On y retrouve dans la plupart des cas deux classes qu'on peut attribuer à la dichotomie connue des fuseaux lents-antérieurs et rapides-postérieurs. On peut aussi s'attendre à d'autres classes ne correspondant pas à des fuseaux, par exemple des FP générés par l'activité alpha; dans ce cas, on retrouverait une classe très lente et très postérieure. La sélection automatique consisterait à représenter de manière efficace les classes obtenues, par exemple par leur centroïdes, et à établir une règle pour déterminer lesquelles correspondent à des fuseaux selon la dichotomie connue.

CONCLUSION

5.7 Contributions originales

La méthodologie de détection proposée a consisté en deux étapes visant respectivement à adresser le problème de sensibilité (manquer le moins possible de fuseaux) et le problème de spécificité (ne pas trop détecter de faux positifs). Une telle approche est retrouvée dans la littérature (Acir et Guzelis, 2004; Schabus et al., 2006). La principale contribution du présent travail est l'utilisation conjointe des caractéristiques de fréquence et de position spatiale (sur l'axe antéro-postérieur), motivée par la dichotomie connue des fuseaux, dans une classification non-supervisée à des fins de spécificité à la deuxième étape de détection. De plus, la sélection des classes a quant à elle été supervisée par un expert qui devait identifier quelques fuseaux à titre d'exemple.

On a aussi proposé une solution à l'analyse d'événements spatialement distribués sur des enregistrements multicanaux en définissant un montage de détection fixe et universel, spécifique aux fuseaux. Les approches trouvées dans la littérature (par exemple, l'ICA, *voir* section 2.4) utilisent des méthodes de décomposition spatiale qui s'adaptent aux signaux, résultant en des représentations spatiales qui varient selon les données, faisant varier d'autant la spécificité spatiale. L'application d'un montage spécifique génère un signal univarié, intégrant l'activité de régions étendues impliquées dans les fuseaux, sur lequel la détection automatique a été effectuée.

Une autre contribution du travail a été la combinaison des approches par fonction de détection et par classification paramétrique en générant une segmentation adaptative des données à partir d'une fonction de détection, définie comme l'enveloppe des oscillations dans la bande fréquentielle des fuseaux. L'extraction de cette fonction de détection a aussi été originale, utilisant une méthode basée sur la Transformée en ondelettes continues, l'analyse de *ridge*, pour extraire l'oscillateur dominant dans la bande des fuseaux avec une résolution temps-fréquence optimale.

La première étape de sélection, sensible, a consisté à seuiller les caractéristiques d'amplitude et de rapport spectral *sigma*. Cette méthode est retrouvée dans la majorité des travaux ayant une approche par fonction de détection (*voir* section 2.2). La contribution réside dans la définition du seuil, individuellement et statistiquement obtenu d'un modèle d'évènement "non-fuseau" généré à partir des évènements se manifestant en stade REM, admis comme ne contenant pas de fuseaux. Ainsi, on n'inclue pas l'activité des fuseaux dans la définition du seuil.

La deuxième étape de sélection, spécifique sur les caractéristiques de fréquence et de position spatiale, a été réalisée par une classification non-supervisée (de type ascendante hiérarchique). Cette technique se distingue de la majorité des travaux de la littérature, qui utilisent plutôt des méthodes de classification supervisées, le plus souvent des réseaux de neurones artificiels et des machines à vecteurs de support (*voir* section 2.3.3). Ceux-ci reposent sur un entraînement à partir d'une base de données supposée représenter la population de tous les fuseaux. Or, les performances de telles méthodes sont sujettes à varier pour différentes populations de sujets, par exemple âgées. La classification non-supervisée du présent travail s'adapte donc à chaque sujet, avec comme originalité que la sélection des classes est supervisée; les classes sélectionnées sont celles regroupant une majorité de fuseaux qu'un expert a identifiés.

5.8 Principaux résultats

La première phase de détection a consisté à seuiller sur les caractéristiques d'amplitude et de rapport spectral *sigma*. Ces seuils ont été déterminés en fixant la *p-value* à $p = 0.1$. La statistique de l'hypothèse nulle (l'évènement considéré n'est *pas* un fuseau) a été estimée à partir des évènements exclusivement en stade REM. L'objectif d'obtenir à ce stade une sensibilité très élevée au prix d'une faible spécificité a été atteint, avec une sensibilité moyenne $Se = 93.2\% \pm 4.8\%$ et une spécificité moyenne $Sp = 1-FPr = 89.0\% \pm 2.1\%$ ($FAr = 0.256 \text{ s}^{-1} \pm 0.048 \text{ s}^{-1}$). La deuxième phase de détection a consisté en une classification ascendante hiérarchique sur les caractéristiques de fréquence et de position spatiale (axe

antéro-postérieur) des évènements sélectionnés à la première phase. La classe retenue a été celle regroupant le plus d'évènements marqués par un expert. L'objectif d'augmenter significativement la spécificité de détection sans trop diminuer la sensibilité a été atteint, avec une sensibilité moyenne $Se = 85.4\% \pm 7.4\%$ et une spécificité moyenne $Sp = 1-FPr = 95.5\% \pm 1.7\%$ ($FAr = 0.105 \text{ s}^{-1} \pm 0.041 \text{ s}^{-1}$). De plus, on a montré que seulement une vingtaine de fuseaux identifiés par l'expert sont nécessaires pour la sélection supervisée des classes.

La dichotomie des fuseaux antérieurs-lents et postérieurs-rapides a été retrouvée chez la plupart des neuf sujets jeunes constituant la base de données à l'étude. De plus, cette caractérisation spatiale et fréquentielle s'est montrée capable d'apporter une spécificité dans la détection automatique des fuseaux. Les résultats obtenus montrent que l'expert marque principalement des fuseaux de la classe spécifique antérieure-rapide. La confirmation de ce résultat considérant le marquage d'autres experts pourrait avoir des implications sur l'interprétation du marquage visuel des fuseaux du sommeil et une meilleure gestion de la spécificité des détecteurs automatiques.

5.9 Perspectives

L'utilisation d'un montage de détection s'est montrée efficace pour analyser des évènements ayant une distribution spatiale spécifique. Ce résultat pourrait avoir des implications dans le développement des futurs détecteurs de fuseaux pour des données plus complexes, comme l'EEG haute densité (128 capteurs et plus) ou la magnétoencéphalographie (MEG). L'étude des fuseaux avec la MEG et l'EEG simultanément est relativement récente, mais montre déjà que les fuseaux vus par la MEG diffèrent de ceux vus simultanément sur l'EEG, montrant entre autres moins de synchronisation durant leur occurrence (Dehghani et al., 2010) et une dynamique spatio-temporo-fréquentielle moins évidente (Dehghani, Cash et Halgren, 2011b).

De récents travaux suggèrent que les deux modalités *voient* deux systèmes distincts impliqués dans la génération des fuseaux : le système cœur (*core*), plus focal et dominant

dans la MEG, et le système matrice (*matrix*), plus distribué et dominant dans l'EEG (Bonjean et al., 2012). Ce dernier pourrait expliquer la grande synchronisation observée dans l'EEG et non dans la MEG. Il serait même possible que le système plus focal, observé par la MEG, précède le système diffus, observé par l'EEG, comme le suggèrent certains résultats (Dehghani, Cash et Halgren, 2011a).

Puisque l'activité MEG est plus focale, une analyse sur des montages particuliers permettrait une spécificité spatiale et une réduction de dimension considérable (la MEG compte généralement plus de 200 capteurs). De plus, en *apprenant* le montage MEG synchrone avec l'activité de fuseau observée simultanément sur l'EEG (par exemple, d'une façon similaire à celle présentée à la Figure 3.1), il serait possible de cibler spécifiquement l'activité du système matrice, dominant en EEG mais faible en MEG. De même, il serait possible d'apprendre le montage MEG du système cœur, associée à certains fuseaux détectés en MEG par un expert, et de lancer un détecteur automatique spécifiquement sur ce montage.

ANNEXE I

FORMALISME SUR LA NOTION D'ÉVÈNEMENT

L'opération de seuillage est une forme de classification qui partitionne le domaine temporel \mathbf{t} en deux ensembles, soit $\mathbf{t} = \tilde{\mathbf{t}}^0 \cup \tilde{\mathbf{t}}^1$ avec $\tilde{\mathbf{t}}^0 \cap \tilde{\mathbf{t}}^1 = \emptyset$ où $\tilde{\mathbf{t}}^1$ représente la partition de \mathbf{t} dont $d(\tilde{\mathbf{t}}^1)$ suggère la présence de fuseaux et $\tilde{\mathbf{t}}^0$, le complément de $\tilde{\mathbf{t}}^1$, représente la partition de \mathbf{t} dont $d(\tilde{\mathbf{t}}^0)$ ne suggère pas la présence de fuseaux :

$$\begin{aligned}\tilde{\mathbf{t}}^1 &= \{t_i \in \mathbf{t} : d(t_i) \geq \tau(t_i)\} \\ \tilde{\mathbf{t}}^0 &= \{t_i \in \mathbf{t} : d(t_i) < \tau(t_i)\}\end{aligned}\quad (\text{A I-1})$$

On dit qu'un évènement débute lorsqu'on passe d'un instant $t_i \in \tilde{\mathbf{t}}^0$ à un instant $t_i \in \tilde{\mathbf{t}}^1$ et qu'un évènement se termine lorsqu'on passe d'un instant $t_i \in \tilde{\mathbf{t}}^1$ à un instant $t_i \in \tilde{\mathbf{t}}^0$. On peut définir ces instants de début et de fin strictement en termes d'instants de $\tilde{\mathbf{t}}^1$:

$$\begin{aligned}\tilde{\mathbf{t}}^{1,\text{début}} &= \{\tilde{t}_i^1 \in \tilde{\mathbf{t}}^1 : \tilde{t}_i^1 - \tilde{t}_{i-1}^1 \neq \Delta t\} \\ \tilde{\mathbf{t}}^{1,\text{fin}} &= \{\tilde{t}_i^1 \in \tilde{\mathbf{t}}^1 : \tilde{t}_{i+1}^1 - \tilde{t}_i^1 \neq \Delta t\}\end{aligned}\quad (\text{A I-2})$$

où Δt représente le pas d'échantillonnage des données EEG. Suivant les conditions $t_1 \in \tilde{\mathbf{t}}^0$ et $t_{N_t} \in \tilde{\mathbf{t}}^0$, où N_t est le nombre total d'instants dans le signal, le nombre d'instants $\tilde{\mathbf{t}}^{1,\text{début}}$ sera égal au nombre d'instants $\tilde{\mathbf{t}}^{1,\text{fin}}$. Chaque paire d'instants de début et de fin correspond à un évènement $\tilde{\mathbf{x}}_n = \begin{bmatrix} \tilde{t}_n^{1,\text{début}} & \tilde{t}_n^{1,\text{fin}} \end{bmatrix}^T$.

Un évènement est ainsi représenté par un vecteur dont chaque élément correspond à une caractéristique (nommé aussi attribut ou paramètre). L'ensemble de N_e évènements est généré en concaténant les vecteurs pour former la matrice $\tilde{\mathbf{X}} = [\tilde{\mathbf{x}}_1, \tilde{\mathbf{x}}_2, \tilde{\mathbf{x}}_3, \tilde{\mathbf{x}}_4]$. Le $i^{\text{ème}}$ évènement est donc représenté par le vecteur colonne $\tilde{\mathbf{x}}_i$ tandis que le vecteur ligne $\tilde{\mathbf{x}}^{(j)}$ représente la $j^{\text{ème}}$ caractéristique à travers les N_e évènements. Si la $j^{\text{ème}}$ caractéristique a comme nom, par exemple, *amplitude*, on représente la $j^{\text{ème}}$ caractéristique à travers les N_e évènements comme $\tilde{\mathbf{x}}^{amplitude}$.

ANNEXE II

MARQUAGE DE L'EXPERT: SOMMEIL ET FUSEAUX

Tableau-A II-1 Quantité de sommeil

	Éveil minutes (%)	NREM1 minutes (%)	NREM2 minutes (%)	NREM3 minutes (%)	NREM4 minutes (%)	REM minutes (%)	TOTAL minutes (%)
Sujet 1	19.0 (3.73 %)	19.7 (3.86 %)	259.7 (50.95 %)	55.0 (10.79 %)	21.7 (4.25 %)	133.3 (26.16 %)	508.3 (99.74 %)
Sujet 2	42.0 (8.55 %)	30.3 (6.17 %)	247.0 (50.27 %)	37.7 (7.67 %)	3.3 (0.68 %)	119.7 (24.36 %)	480.0 (97.69 %)
Sujet 3	19.3 (3.79 %)	10.0 (1.96 %)	286.3 (56.18 %)	49.3 (9.68 %)	11.0 (2.16 %)	132.0 (25.90 %)	508.0 (99.67 %)
Sujet 4	48.3 (8.95 %)	20.3 (3.76 %)	305.0 (56.45 %)	52.7 (9.75 %)	10.7 (1.97 %)	72.7 (13.45 %)	509.7 (94.32 %)
Sujet 5	104.7 (19.42 %)	66.0 (12.24 %)	272.3 (50.53 %)	5.7 (1.05 %)	0.0 (0.00 %)	90.0 (16.70 %)	538.7 (99.94 %)
Sujet 6	16.7 (3.41 %)	23.7 (4.85 %)	324.0 (66.35 %)	1.3 (0.27 %)	0.0 (0.00 %)	109.3 (22.39 %)	475.0 (97.27 %)
Sujet 7	88.7 (16.53 %)	37.3 (6.96 %)	272.0 (50.71 %)	41.3 (7.71 %)	2.3 (0.44 %)	67.3 (12.55 %)	509.0 (94.90 %)
Sujet 8	12.0 (2.86 %)	12.3 (2.94 %)	263.3 (62.75 %)	40.0 (9.53 %)	5.0 (1.19 %)	86.7 (20.65 %)	419.3 (99.92 %)
Sujet 9	7.0 (1.54 %)	13.0 (2.87 %)	237.3 (52.35 %)	52.7 (11.62 %)	7.0 (1.54 %)	135.7 (29.93 %)	452.7 (99.85 %)
Moyenne	39.7 (7.64 %)	25.9 (5.07 %)	274.1 (55.17 %)	37.3 (7.56 %)	6.8 (1.36 %)	105.2 (21.34 %)	489.0 (98.15 %)
Écart- type	35.2 (6.41 %)	17.5 (3.13 %)	27.4 (5.88 %)	20.2 (4.12 %)	6.9 (1.34 %)	26.8 (6.01 %)	36.2 (2.24 %)

Tableau-A II-2 Nombre de fuseaux marqués par l'expert

	Fz	Cz	Pz	Union¹	Distinct²
Sujet 1	99	223	283	605	391
Sujet 2	44	110	212	366	258
Sujet 3	344	625	401	1370	752
Sujet 4	23	45	64	132	97
Sujet 5	117	206	180	503	308
Sujet 6	96	375	702	1173	775
Sujet 7	8	50	49	107	75
Sujet 8	40	109	190	339	256
Sujet 9	268	360	403	1031	602
Total	1039	2103	2484	5626	3514
Moyenne	115	234	276	625	390
Écart-type	116	190	203	460	263

¹ Union : somme des évènements détectés sur Fz, Cz et Pz

² Distinct : sans doublon; un doublon correspond à des fuseaux, sur au moins deux capteurs, qui concordent temporellement

ANNEXE III

ÉVÈNEMENTS DÉTECTÉS

Tableau-A III-1 Quantité d'évènements détectés par montage

	m1	m2	m3	m4	m5	m6	Moy.
Sujet 1	77349	72918	74214	75674	75489	72340	74664
Sujet 2	70011	67821	67841	68725	68997	66619	68336
Sujet 3	75571	77555	75664	75731	75938	74349	75801
Sujet 4	74248	74091	73674	75067	74058	73060	74033
Sujet 5	82454	80196	81519	81406	81667	80271	81252
Sujet 6	73983	70864	71276	73404	71886	69460	71812
Sujet 7	74709	71343	71935	73125	72550	71282	72491
Sujet 8	62222	60715	59276	62059	61599	57803	60612
Sujet 9	68082	69203	66341	66238	67406	67352	67437
Moyenne	73181	71634	71304	72381	72177	70282	71826
Écart-type	5802	5661	6316	5809	5741	6202	5865

ANNEXE IV

PERFORMANCE

Tableau-A IV-1 Performance au régime optimal ($Se \cong Sp$)

	Se (-)	FPr (-)	FPa (-)	FAr (1/s)	FPp (-)
Sujet 1	0.883	0.109	0.936	0.258	12.989
Sujet 2	0.922	0.077	0.934	0.176	12.953
Sujet 3	0.949	0.060	0.782	0.146	3.412
Sujet 4	0.881	0.112	0.983	0.254	51.780
Sujet 5	0.964	0.038	0.865	0.093	6.169
Sujet 6	0.947	0.055	0.766	0.133	3.101
Sujet 7	0.926	0.076	0.982	0.169	50.287
Sujet 8	0.889	0.113	0.944	0.263	14.995
Sujet 9	0.924	0.075	0.829	0.165	4.479
Global¹	0.917	0.081	0.910	0.190	15.946
Moyenne	0.921	0.079	0.891	0.184	17.796
Écart-type	0.030	0.027	0.083	0.061	19.366

¹ Les points optimaux de la rangée *Global* sont obtenus de la courbe ROC moyenne à travers les sujets; la rangée *Moyenne* correspond à la moyenne des points optimaux à travers les sujets.

Tableau-A IV-2 Performance à la première phase de détection ($p = 0.1$)

	Se (-)	FPr (-)	FPa (-)	FAr (1/s)	FPp (-)
Sujet 1	0.867	0.092	0.926	0.217	10.906
Sujet 2	0.955	0.148	0.963	0.339	25.027
Sujet 3	0.979	0.122	0.877	0.298	6.972
Sujet 4	0.874	0.094	0.980	0.214	43.667
Sujet 5	0.976	0.087	0.936	0.216	14.252
Sujet 6	0.974	0.125	0.879	0.303	7.076
Sujet 7	0.944	0.103	0.986	0.229	68.333
Sujet 8	0.871	0.092	0.933	0.214	12.199
Sujet 9	0.950	0.126	0.888	0.277	7.506
Moyenne	0.932	0.110	0.930	0.256	21.771
Écart-type	0.048	0.021	0.042	0.048	21.103

Tableau-A IV-3 Performance à la deuxième phase de détection

	Se (-)	FPr (-)	FPa (-)	FAr (1/s)	FPp (-)
Sujet 1	0.832	0.029	0.806	0.069	3.461
Sujet 2	0.845	0.051	0.911	0.117	8.620
Sujet 3	0.928	0.069	0.810	0.169	3.953
Sujet 4	0.711	0.017	0.916	0.038	7.717
Sujet 5	0.950	0.048	0.892	0.119	7.837
Sujet 6	0.881	0.060	0.795	0.146	3.410
Sujet 7	0.917	0.033	0.960	0.075	22.241
Sujet 8	0.804	0.039	0.866	0.091	5.194
Sujet 9	0.822	0.056	0.800	0.122	3.297
Moyenne	0.854	0.045	0.862	0.105	7.303
Écart-type	0.074	0.017	0.061	0.041	5.989

LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES

- Acir, Nurettin, et Cuneyt Guzelis. 2004. « Automatic recognition of sleep spindles in EEG by using artificial neural networks ». *Expert Systems with Applications*, vol. 27, n° 3, p. 451-458.
- Ahmed, B., A. Redissi et R. Tafreshi. 2009. « An automatic sleep spindle detector based on wavelets and the teager energy operator ». *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference*, vol. 2009, p. 2596-9.
- Anderer, P., G. Gruber, S. Parapatics, M. Woertz, T. Miazhynskaia, G. Klosch, B. Saletu, J. Zeilhofer, M. J. Barbanjo, H. Danker-Hopfe, S. L. Himanen, B. Kemp, T. Penzel, M. Grozinger, D. Kunz, P. Rappelsberger, A. Schlogl et G. Dorffner. 2005. « An E-health solution for automatic sleep classification according to Rechtschaffen and Kales: validation study of the Somnolyzer 24 x 7 utilizing the Siesta database ». *Neuropsychobiology*, vol. 51, n° 3, p. 115-33.
- Ayoub, A., M. Molle, H. Preissl et J. Born. 2012. « Grouping of MEG gamma oscillations by EEG sleep spindles ». *NeuroImage*, vol. 59, n° 2 (Jan 16), p. 1491-500.
- Babadi, B., S. M. McKinney, V. Tarokh et J. M. Ellenbogen. 2012. « DiBa: A Data-Driven Bayesian Algorithm for Sleep Spindle Detection ». *IEEE Transactions on Bio-Medical Engineering*, vol. 59, n° 2 (Feb), p. 483-93.
- Barakat, M., J. Doyon, K. Debas, G. Vandewalle, A. Morin, G. Poirier, N. Martin, M. Lafortune, A. Karni, L. G. Ungerleider, H. Benali et J. Carrier. 2011. « Fast and slow spindle involvement in the consolidation of a new motor sequence ». *Behavioural Brain Research*, vol. 217, n° 1 (Feb 2), p. 117-21.
- Barros, A.K., R. Rosipal, M. Girolami, G. Dorffner et N. Ohnishi. 2000. « Extraction of sleep-spindles from the electroencephalogram (EEG) ». *Artificial Neural Networks in Medicine and Biology (ANNIMAB-1)*, Springer, Goteborg, Sweden, p. 125-130.
- Benbadis, Selim, Aatif Husain, Peter Kaplan et William Tatum. 2007. *Handbook of EEG Interpretation*. Demos Medical Publishing.
- Bodizs, R., J. Kormendi, P. Rigo et A. S. Lazar. 2009. « The individual adjustment method of sleep spindle analysis: methodological improvements and roots in the fingerprint paradigm ». *Journal of Neuroscience Methods*, vol. 178, n° 1 (Mar 30), p. 205-13.
- Bonjean, M., T. Baker, M. Bazhenov, S. Cash, E. Halgren et T. Sejnowski. 2012. « Interactions between core and matrix thalamocortical projections in human sleep

- spindle synchronization ». *The Journal of Neuroscience : the official journal of the Society for Neuroscience*, vol. 32, n° 15 (Apr 11), p. 5250-63.
- Broughton, R., T. Healey, J. Maru, D. Green et B. Pagurek. 1978. « A phase locked loop device for automatic detection of sleep spindles and stage 2 ». *Electroencephalography and Clinical Neurophysiology*, vol. 44, n° 5 (May), p. 677-80.
- Caplan, Jeremy B., Joseph R. Madsen, Sridhar Raghavachari et Michael J. Kahana. 2001. « Distinct Patterns of Brain Oscillations Underlie Two Basic Parameters of Human Maze Learning ». *Journal of Neurophysiology*, vol. 86, n° 1 (July 1, 2001), p. 368-380.
- Causa, L., C. M. Held, J. Causa, P. A. Estevez, C. A. Perez, R. Chamorro, M. Garrido, C. Algarin et P. Peirano. 2010. « Automated sleep-spindle detection in healthy children polysomnograms ». *IEEE Transactions on Bio-Medical Engineering*, vol. 57, n° 9 (Sep), p. 2135-46.
- De Gennaro, L., et M. Ferrara. 2003. « Sleep spindles: an overview ». *Sleep Medicine Reviews*, vol. 7, n° 5 (Oct), p. 423-40.
- Dehghani, N., S. S. Cash et E. Halgren. 2011a. « Emergence of synchronous EEG spindles from asynchronous MEG spindles ». *Human Brain Mapping*, (Feb 17).
- Dehghani, N., S. S. Cash et E. Halgren. 2011b. « Topographical frequency dynamics within EEG and MEG sleep spindles ». *Clinical Neurophysiology : Official Journal of the International Federation of Clinical Neurophysiology*, vol. 122, n° 2 (Feb), p. 229-35.
- Dehghani, N., S. S. Cash, A. O. Rossetti, C. C. Chen et E. Halgren. 2010. « Magnetoencephalography demonstrates multiple asynchronous generators during human sleep spindles ». *Journal of Neurophysiology*, vol. 104, n° 1 (Jul), p. 179-88.
- Devuyst, S., T. Dutoit, J. F. Didier, F. Meers, E. Stanus, P. Stenuit et M. Kerkhofs. 2006. « Automatic sleep spindle detection in patients with sleep disorders ». *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference*, vol. 1, p. 3883-6.
- Devuyst, S., T. Dutoit, P. Stenuit et M. Kerkhofs. 2011. « Automatic sleep spindles detection--overview and development of a standard proposal assessment method ». *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference*, vol. 2011, p. 1713-6.

- Duman, Fazil, Aykut Erdamar, Osman Erogul, Ziya Telatar et Sinan Yetkin. 2009. « Efficient sleep spindle detection algorithm with decision tree ». *Expert Systems with Applications*, vol. 36, n° 6, p. 9980-9985.
- Durka, P. J., A. Matysiak, E. M. Montes, P. V. Sosa et K. J. Blinowska. 2005. « Multichannel matching pursuit and EEG inverse solutions ». *Journal of Neuroscience Methods*, vol. 148, n° 1 (Oct 15), p. 49-59.
- Ferrarelli, F., R. Huber, M. J. Peterson, M. Massimini, M. Murphy, B. A. Riedner, A. Watson, P. Bria et G. Tononi. 2007. « Reduced sleep spindle activity in schizophrenia patients ». *The American Journal of Psychiatry*, vol. 164, n° 3 (Mar), p. 483-92.
- Gorur, D., H. Aydin, G. Ongun, F. Ozgen et K. Leblebicioglu. 2003. « Sleep spindles detection using autoregressive modeling ». *Proceedings of ICANN*.
- Gorur, D., U. Halici, H. Aydin, G. Ongun, F. Ozgen et K. Leblebicioglu. 2002. « Sleep spindles detection using short time Fourier transform and neural networks ». In *Neural Networks, 2002. IJCNN '02. Proceedings of the 2002 International Joint Conference on* (2002). Vol. 2, p. 1631-1636.
- Held, C. M., L. Causa, P. Estevez, C. Perez, M. Garrido, C. Algarin et P. Peirano. 2004. « Dual approach for automated sleep spindles detection within EEG background activity in infant polysomnograms ». *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference*, vol. 1, p. 566-9.
- Huupponen, E., G. Gomez-Herrero, A. Saastamoinen, A. Varri, J. Hasan et S. L. Himanen. 2007. « Development and comparison of four sleep spindle detection methods ». *Artificial Intelligence in Medicine*, vol. 40, n° 3 (Jul), p. 157-70.
- Huupponen, E., A. Kulkas, M. Tenhunen, A. Saastamoinen, J. Hasan et S. L. Himanen. 2008. « Diffuse sleep spindles show similar frequency in central and frontopolar positions ». *Journal of Neuroscience Methods*, vol. 172, n° 1 (Jul 15), p. 54-9.
- Huupponen, E., A. Saastamoinen, J. Niemi, J. Virkkala, J. Hasan, A. Varri et S. L. Himanen. 2005. « Automated frequency analysis of synchronous and diffuse sleep spindles ». *Neuropsychobiology*, vol. 51, n° 4, p. 256-64.
- Huupponen, E., A. Varri, S. L. Himanen, J. Hasan, M. Lehtokangas et Saarinen. 2000a. « Optimization of sigma amplitude threshold in sleep spindle detection ». *Journal of Sleep Research*, vol. 9, n° 4 (Dec), p. 327-34.
- Huupponen, E., A. Varri, S. L. Himanen, J. Hasan, M. Lehtokangas et J. Saarinen. 2000b. « Autoassociative MLP in sleep spindle detection ». *Journal of Medical Systems*, vol. 24, n° 3 (Jun), p. 183-93.

- Iber, C., S. Ancoli-Israel, A. Chesson et SF. Quan. 2007. *The AASM Manual for the Scoring of Sleep and Associated Events*. Westchester, IL: American Academy of Sleep Medicine.
- Kumar, A., W. Hofman et K. Campbell. 1979. « An automatic spindle analysis and detection system based on the evaluation of human ratings of the spindle quality ». *Waking and Sleeping*, vol. 3, n° 4 (Sep-Dec), p. 325-33.
- Lee-Chiong, T. 2008. *Sleep Medicine: Essentials and Review*. Oxford University Press, USA.
- Lilly, J.M., et S.C. Olhede. 2009. « Higher-order properties of analytic wavelets ». *Signal Processing, IEEE Transactions on*, vol. 57, n° 1, p. 146-160.
- Lilly, J.M., et S.C. Olhede. 2010. « On the analytic wavelet transform ». *Information Theory, IEEE Transactions on*, vol. 56, n° 8, p. 4135-4156.
- Malinowska, U., P. J. Durka, J. Zygierewicz, W. Szelenberger et A. Wakarow. 2007. « Explicit parameterization of sleep EEG transients ». *Computers in Biology and Medicine*, vol. 37, n° 4 (Apr), p. 534-41.
- Mallat, S. 1999. *A Wavelet Tour of Signal Processing*. Academic Press.
- Malmivuo, J., et R. Plonsey. 1995. *Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields*. Oxford University Press, USA.
- Marieb, E.N., et R. Lachaîne. 2005. *Anatomie et physiologie humaines*. Éditions du Renouveau pédagogique.
- Martin, N., M. Lafortune, J. Godbout, M. Barakat, R. Robillard, G. Poirier, C. Bastien et J. Carrier. 2012. « Topography of age-related changes in sleep spindles ». *Neurobiology of Aging*, (Jul 16).
- Mindell, J.A., et J.A. Owens. 2009. *A Clinical Guide to Pediatric Sleep: Diagnosis and Management of Sleep Problems*. Lippincott Williams & Wilkins.
- Molle, M., T. O. Bergmann, L. Marshall et J. Born. 2011. « Fast and slow spindles during the sleep slow oscillation: disparate coalescence and engagement in memory processing ». *Sleep*, vol. 34, n° 10 (Oct), p. 1411-21.
- Molle, M., L. Marshall, S. Gais et J. Born. 2002. « Grouping of spindle activity during slow oscillations in human non-rapid eye movement sleep ». *The Journal of Neuroscience : the Official Journal of the Society for Neuroscience*, vol. 22, n° 24 (Dec 15), p. 10941-7.

- Morin, C.M., et C. Espie. 2012. *The Oxford Handbook of Sleep and Sleep Disorders*. OUP USA.
- Niedermeyer, E., et F.H.L. Da Silva. 2005. *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. Lippincott Williams & Wilkins.
- Olbrich, E., et P. Achermann. 2005. « Analysis of oscillatory patterns in the human sleep EEG using a novel detection algorithm ». *Journal of Sleep Research*, vol. 14, n° 4 (Dec), p. 337-46.
- Oostenveld, Robert, Pascal Fries, Eric Maris et Jan-Mathijs Schoffelen. 2011. « FieldTrip: Open Source Software for Advanced Analysis of MEG, EEG, and Invasive Electrophysiological Data ». *Computational Intelligence and Neuroscience*, vol. 2011.
- Ray, L. B., S. M. Fogel, C. T. Smith et K. R. Peters. 2010. « Validating an automated sleep spindle detection algorithm using an individualized approach ». *Journal of Sleep Research*, vol. 19, n° 2 (Jun), p. 374-8.
- Rechtschaffen, A., et A. Kales. 1968. *A Manual of Standardized Terminology, Techniques, and Scoring System for Sleep Stages of Human Subjects*. US Department of Health, Education, and Welfare Public Health Service - NIH/NIND.
- Rosipal, R., G. Dorffner et E. Trenker. 1998. « Can ICA improve sleep-spindles detection? ». *Neural Network World*, vol. 8, p. 539-548.
- Sanei, S., et J. Chambers. 2007. *EEG Signal Processing*. John Wiley & Sons.
- Schabus, M., T. T. Dang-Vu, G. Albouy, E. Balteau, M. Boly, J. Carrier, A. Darsaud, C. Degueldre, M. Desseilles, S. Gais, C. Phillips, G. Rauchs, C. Schnakers, V. Sterpenich, G. Vandewalle, A. Luxen et P. Maquet. 2007. « Hemodynamic cerebral correlates of sleep spindles during human non-rapid eye movement sleep ». *Proceedings of the National Academy of Sciences of the United States of America*, vol. 104, n° 32 (Aug 7), p. 13164-9.
- Schabus, M., K. Hodlmoser, G. Gruber, C. Sauter, P. Anderer, G. Klosch, S. Parapatics, B. Saletu, W. Klimesch et J. Zeitlhofer. 2006. « Sleep spindle-related activity in the human EEG and its relation to general cognitive and learning abilities ». *The European Journal of Neuroscience*, vol. 23, n° 7 (Apr), p. 1738-46.
- Schimicek, P., J. Zeitlhofer, P. Anderer et B. Saletu. 1994. « Automatic sleep-spindle detection procedure: aspects of reliability and validity ». *Clinical EEG*, vol. 25, n° 1 (Jan), p. 26-9.

- Schonwald, S. V., E. L. de Santa-Helena, R. Rossatto, M. L. Chaves et G. J. Gerhardt. 2006. « Benchmarking matching pursuit to find sleep spindles ». *Journal of Neuroscience Methods*, vol. 156, n° 1-2 (Sep 30), p. 314-21.
- Sciarretta, G., et A. Bricolo. 1970. « Automatic detection of sleep spindles by analysis of harmonic components ». *Medical & Biological Engineering*, vol. 8, n° 5 (Sep), p. 517-9.
- Sinha, R. K. 2008. « Artificial neural network and wavelet based automated detection of sleep spindles, REM sleep and wake states ». *Journal of Medical Systems*, vol. 32, n° 4 (Aug), p. 291-9.
- Steriade, M. 2003. « The corticothalamic system in sleep ». *Frontiers in Bioscience : A Journal and Virtual Library*, vol. 8, (May 1), p. d878-99.
- Steriade, M. 2006. « Grouping of brain rhythms in corticothalamic systems ». *Neuroscience*, vol. 137, n° 4, p. 1087-106.
- Timm, N.H. 2002. *Applied Multivariate Analysis*. Springer.
- Ventouras, E. M., I. Alevizos, P. Y. Ktonas, H. Tsekou, T. Paparrigopoulos, I. Kalatzis, C. R. Soldatos et G. Nikiforidis. 2007. « Independent components of sleep spindles ». *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference*, vol. 2007, p. 4002-5.
- Ventouras, E. M., P. Y. Ktonas, H. Tsekou, T. Paparrigopoulos, I. Kalatzis et C. R. Soldatos. 2010. « Independent component analysis for source localization of EEG sleep spindle components ». *Computational Intelligence and Neuroscience*, p. 329436.
- Ventouras, E. M., E. A. Monoyiou, P. Y. Ktonas, T. Paparrigopoulos, D. G. Dikeos, N. K. Uzunoglu et C. R. Soldatos. 2005. « Sleep spindle detection using artificial neural networks trained with filtered time-domain EEG: a feasibility study ». *Computer Methods and Programs in Biomedicine*, vol. 78, n° 3 (Jun), p. 191-207.
- Whitten, T. A., A. M. Hughes, C. T. Dickson et J. B. Caplan. 2011. « A better oscillation detection method robustly extracts EEG rhythms across brain state changes: the human alpha rhythm as a test case ». *NeuroImage*, vol. 54, n° 2 (Jan 15), p. 860-74.
- Zygierek, J., K. J. Blinowska, P. J. Durka, W. Szelenberger, S. Niemcewicz et W. Androsiuk. 1999. « High resolution study of sleep spindles ». *Clinical Neurophysiology : Official Journal of the International Federation of Clinical Neurophysiology*, vol. 110, n° 12 (Dec), p. 2136-47.