


MSc HES-SO en Business Administration

Orientation :
Management des Systèmes d'Information

Le Machine Learning permet-il
de prédire les détériorations
comportementales et cérébrales
induites par la vieillesse ?



Réalisé par
Ranjith Steve Sivagnanaselvam

Sous la direction de
Prof. Dominique Genoud

Lausanne, le 29 août 2016

L'illustration de la page de titre est adaptée de :
https://image.freepik.com/free-vector/artificial-brain_23-2147499616.jpg

Table des matières

| | |
|---|------|
| Remerciements | v |
| Abréviations | vi |
| Résumé | vii |
| Abstract | viii |
| 1. Introduction | 1 |
| 1.1. Contexte | 1 |
| 1.2. Question de recherche et objectifs | 2 |
| 1.3. Périmètre et limites de l'étude | 2 |
| 2. Etat de l'art | 3 |
| 2.1. Posturographie | 3 |
| 2.2. L'IRM | 4 |
| 2.3. Imagerie motrice et observation d'action | 5 |
| 2.4. Le Machine Learning | 6 |
| 2.4.1. Apprentissages supervisés et non supervisés | 6 |
| 2.4.2. Modélisation | 7 |
| 2.4.3. Evaluation des classificateurs | 8 |
| 2.4.4. Validation croisée « leave-one-out » | 10 |
| 2.5. Littérature sur la sénescence et le Machine Learning | 10 |
| 2.5.1. Régions cérébrales impliquées dans le contrôle de l'équilibre | 11 |
| 2.5.2. Détériorations comportementales accompagnant la sénescence | 11 |
| 2.5.3. Utilisation du Machine Learning en lien avec les changements cérébraux et comportementaux chez les seniors | 11 |
| 2.5.4. Synthèse sur les régions cérébrales | 12 |
| 2.6. Synthèse sur l'état de l'art | 14 |
| 3. Méthodologie | 15 |
| 3.1. Comparaison des méthodologies de découverte de connaissance | 15 |
| 3.2. Méthodologie adoptée – CRISP-DM | 17 |
| 3.3. Acquisition des données | 18 |
| 3.3.1. Mesures comportementales | 19 |
| 3.3.2. Mesures IRM | 19 |
| 3.4. Classification du type de travail | 20 |
| 3.5. Plateforme de Machine Learning | 20 |
| 4. Analyse et développement | 22 |
| 4.1. Données initiales | 22 |
| 4.1.1. Données sur l'équilibre | 22 |
| 4.1.2. Données sur l'IRM | 23 |
| 4.1.3. Vue d'ensemble | 24 |
| 4.2. Préparation des données | 24 |
| 4.2.1. Données comportementales | 24 |
| 4.2.2. Nettoyage et préparation des données fMRI | 26 |
| 4.2.3. Nettoyage et préparation des données sMRI | 27 |
| 4.3. Itération 1 – Exploration des jeux de données | 29 |
| 4.3.1. Description | 29 |
| 4.3.2. Machine Learning | 29 |
| 4.3.3. Résultats et discussions | 30 |
| 4.4. Itération 2 – Réduction du bruit dans les données fMRI | 32 |

| | |
|--|----|
| 4.4.1. Description | 32 |
| 4.4.2. Flux de préparation | 33 |
| 4.4.3. Machine Learning | 33 |
| 4.4.4. Résultats et discussions | 34 |
| 4.5. Itération 3 – Autres classificateurs | 36 |
| 4.5.1. Description | 36 |
| 4.5.2. Flux de préparation | 36 |
| 4.5.3. Machine Learning | 36 |
| 4.5.4. Résultats et discussions | 37 |
| 4.6. Itération 4 – combinaison fMRI avec sMRI | 38 |
| 4.6.1. Description | 38 |
| 4.6.2. Flux de préparation | 38 |
| 4.6.3. Machine Learning | 39 |
| 4.6.4. Résultats et discussions | 39 |
| 4.7. Itération 5 – Détection des éléments mal classés | 40 |
| 4.7.1. Description | 40 |
| 4.7.2. Flux de préparation | 40 |
| 4.7.3. Machine Learning | 40 |
| 4.7.4. Résultats et discussions | 40 |
| 4.8. Itération 6 – Amélioration des résultats sMRI | 41 |
| 4.8.1. Description | 41 |
| 4.8.2. Flux de préparation | 42 |
| 4.8.3. Machine Learning | 42 |
| 4.8.4. Résultats et discussions | 42 |
| 5. Synthèse et conclusion | 44 |
| 5.1. Synthèse des résultats obtenus | 44 |
| 5.2. Synthèse globale | 45 |
| 5.3. Conclusion | 46 |
| 6. Références | 48 |
| 7. Liste des tableaux | 52 |
| 8. Liste des figures | 52 |
| 9. Liste des équations | 53 |
| 10. Annexes | 54 |
| 10.1. Critères d'exclusion pour la participation à l'étude | 54 |
| 10.2. Extraits vidéos des conditions AOP et AOS | 55 |
| 10.3. Aide postée sur le forum Knime | 56 |

« La vie, c'est comme une bicyclette, il faut avancer pour ne pas perdre l'équilibre. »

Albert Einstein (1879-1955)

Remerciements

Je souhaite remercier en premier lieu Dominique Genoud, Professeur à l'Institut d'Informatique de Gestion de la HES-SO Valais, d'avoir accepté de suivre mon travail. Je le suis reconnaissant pour son appui et ses conseils avisés tout au long de ce projet.

Mes remerciements vont également à mon entourage et ma famille pour leur soutien tout au long de cette étude.

Abréviations

| | |
|----------|---|
| AD | Alzheimer Disease (maladie d'Alzheimer) |
| AOP | Action Observation of a Perturbation (observation d'action d'une perturbation) |
| AOS | Action Observation of a Static balance task (observation d'action d'une tâche statique d'équilibre) |
| AUC | Area Under the Curve (aire sous la courbe) |
| BG | Basal Ganglia (ganglions de la base) |
| CI | Confidence Interval (intervalle de confiance) |
| COP | Center of Pressure (centre de pression) |
| CRISP-DM | CRoss Industry Standard Process for Data Mining |
| CSV | Comma-Separated Values (valeurs séparées par des virgules) |
| DA | Data Analyst (analyste de données) |
| DM | Data Mining (forage des données) |
| fMRI | Functional Magnetic Resonance Imaging (IRM fonctionnelle) |
| HES-SO | Haute Ecole Spécialisée de Suisse Occidentale |
| IM | Imagerie motrice |
| KD | Knowledge Discovery (découverte de la connaissance) |
| KDD | Knowledge Discovery in Databases (découverte de connaissances dans les bases de données) |
| kNN | k-Nearest Neighbour (k plus proches voisins) |
| LCS | Liquide Cérébro-Spinal |
| M1 | Cortex moteur primaire |
| ML | Machine Learning (apprentissage machine) |
| MRI | Magnetic Resonance Imaging (imagerie par resonance magnétique) |
| OA | Observation d'Action |
| OFS | Office Fédéral de la Statistique |
| PFC | Pre Frontal Cortex (cortex pré-frontal) |
| PMC | Premotor Cortex (cortex pré-moteur) |
| ROC | Receiver Operating Characteristic (caractéristique de fonctionnement du récepteur) |
| ROI | Region of Interest (région d'intérêt) |
| S1 | Primary Somatosensory Cortex (cortex somatosensoriel primaire) |
| SD | Standard Deviation (écart-type) |
| SMA | Supplementary motor area (aire motrice supplémentaire) |
| sMRI | Structural Magnetic Resonance Imaging (IRM structurelle) |
| SP | Sway Path (chemin de blancement) |
| VBM | Voxel-Based Morphometry (morphométrie basée sur les voxels) |
| Voxel | Volumetric Pixel (pixel volumétrique) |

N.B. : le présent document contient un certain nombre d'abréviations provenant majoritairement de l'anglais. Le choix a été retenu de préserver les abréviations dans leur forme originelle afin de rester fidèle à la littérature plus abondante dans cette langue.

Résumé

Le vieillissement est accompagné de changements cérébraux structurels et fonctionnels. Il est également admis que la posture se détériore avec l'âge. Bien qu'à l'heure actuelle, les connexions entre les déficits cognitifs et la sénescence aient été étudiées, les relations avec les performances motrices sont encore peu connues. Dans ce travail, il est question d'étudier l'hypothèse selon laquelle le Machine Learning permettrait de prédire les détériorations cérébrales en fonction de la capacité d'équilibre chez les seniors.

Les données utilisées sont issues d'une étude menée à l'Université de Fribourg. Elles ont été acquises sur 35 sujets consentants et en bonne santé âgés entre 65 et 80 ans (moyenne : 70.9 ans, écart-type : 4.5 ans). Ces participants ont suivi des acquisitions au scanner IRM pour obtenir les données structurelles et fonctionnelles du cerveau. Durant l'acquisition fonctionnelle, les sujets avaient un écran sur lequel une vidéo était présentée et ils devaient s'imaginer activement contrer une perturbation dynamique (AOP) ou s'imaginer effectuer une tâche d'équilibre statique (AOS). De ces conditions sont tirées deux lignes de référence pour l'activation cérébrale qui sont AOP-Repos et AOP-AOS. Pour obtenir les données comportementales, l'équilibre des sujets a été mesuré à l'aide d'une plaque de force où le chemin de balancement (sway path) a été mesuré lors de la tenue en équilibre sur le pied droit pendant 15 secondes. Basé sur ce chemin de balancement, un seuil a permis de classer les sujets comme ayant un bon ou mauvais équilibre.

L'analyse des données récoltées s'est faite à l'aide du processus CRISP-DM et du logiciel Knime. Le Machine Learning a été utilisé afin de découvrir les liens entre les mesures comportementales et cérébrales. Plusieurs algorithmes de Machine Learning ont été utilisés afin de pouvoir les comparer : forêt d'arbres décisionnels, arbres de décisions, k plus proches voisins et réseaux de neurones. La comparaison de la performance s'est faite à l'aide de l'aire sous la courbe de ROC (AUC).

L'obtention des résultats s'est fait au terme de 6 itérations, parmi lesquelles des hypothèses ont été émises et répondues à tour de rôle. Parmi les données fonctionnelles, dans la condition AOP-Repos, la région d'intérêt (ROI) du cortex pré-frontal (PFC) a permis d'obtenir une AUC de 0.86 (écart-type 0.08) avec le classificateur des arbres de décisions. Dans la condition AOP-AOS, le cortex somatosensoriel primaire (S1) prédit avec une AUC de 0.90 (écart-type 0.07) avec le classificateur des réseaux de neurones. Dans cette même condition, la prise en compte du cerveau dans son entier a permis d'obtenir une AUC de 0.81 (écart-type 0.10), également avec les réseaux de neurones. Pour ce qui est des données structurelles, le cortex moteur primaire (M1) est la ROI qui prédit le mieux les défaillances comportementales avec une AUC de 0.78 (écart-type de 0.10) à l'aide du classificateur de la forêt d'arbres décisionnels. En dernier lieu, la combinaison des données structurelles de la région M1 et fonctionnelles de la région PFC dans la condition AOP-Repos, permet d'obtenir une AUC de 0.90 (écart-type de 0.07) avec le classificateur des arbres de décisions.

Ces résultats montrent que le Machine Learning est un outil prometteur pour prédire les détériorations comportementales et cérébrales chez les personnes âgées. En outre, ce travail a permis de mettre en relation des mesures liées aux activités motrices avec celles du cerveau, une approche encore peu explorée dans le domaine scientifique. Ces découvertes peuvent servir de prémices pour établir des pré-diagnostic opérant comme aide à la décision sur les mesures à prendre pour une personne dont l'autonomie pourrait se voir menacée avant même que des symptômes de détériorations cérébrales ou posturographiques ne soient réellement observés. En outre, elles permettraient d'évaluer les traitements médicaux et les entraînements physiques afin de déterminer si ces derniers sont efficaces pour retarder les effets de la vieillesse.

Mots-clés : Machine Learning, IRM fonctionnelle, IRM structurelle, Knime, vieillesse

Abstract

Aging is accompanied by structural and functional cerebral changes. It is also admitted that postural changes worsens with years. Although at the present time connexions between cognitive deficits and senescence were studied, the relationships with motor performances are still not well known. In this work, we will explore whether Machine Learning would make it possible to predict cerebral deteriorations in relation with the capacity of balance of elderly people.

The data used result from a study conducted at the University of Fribourg. They were acquired on 35 agreeing subjects in good health, aged between 65 and 80 years (average: 70.9 years, standard deviation (SD): 4.5 years). These participants carried acquisitions in an MRI scanner to obtain structural and functional brain data. During functional acquisitions, the subjects had a screen on which a video was presented and they had to imagine counter a dynamic perturbation with active observation (AOP) or think to carry out a task of static balance (AOS). From these conditions two baselines for cerebral activation are drawn, which are AOP-Rest and AOP-AOS. To obtain behavioural data, the balance of the subjects was measured with a force plate where the sway path was calculated while standing on the right foot during 15 seconds. Based on this sway path, a threshold was used to classify the subjects as having a good or bad balance.

The analysis of collected data was done using the CRISP-DM process and the Knime software. Machine Learning was used to discover the links between behavioural and cerebral measurements. Several Machine Learning algorithms were used in order to compare them: tree ensemble, decision trees, k-nearest neighbours and neuronal networks. Comparison of performance was done using the area under ROC curve (AUC).

The results were obtained at the end of 6 iterations among which hypotheses were emitted and answered. Regarding the functional data, under the condition AOP-AOS, region of interest (ROI) of pre frontal cortex (PFC) obtained an AUC of 0.86 (SD: 0.08) with the decision trees classifier. Under the condition AOP-AOS, the primary somatosensory cortex (S1) predicted with an AUC of 0.9 (SD: 0.07) with the neuronal networks classifier. Under this same condition, taking into account the whole brain obtained an AUC of 0.81 (SD: 0.10), also with neuronal networks. As far as structural data are concerned, the primary motor cortex (M1) is the ROI that best predicts behavioural failures with an AUC of 0.78 (SD: 0.10) using the ensemble tree classifier. Lastly, combination of structural data of the M1 area with the functional ones of area PFC under AOP-Rest condition obtained an AUC of 0.90 (SD: 0.07) with the classifier of decision trees.

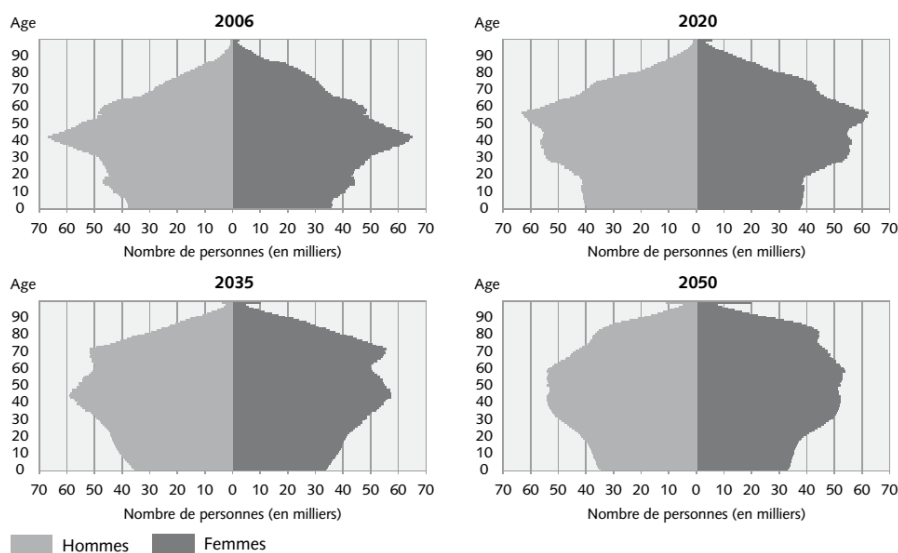
These results show that Machine Learning is a promising tool to predict behavioural and cerebral deteriorations of elderly people. Moreover, this work made it possible to establish connexions with measurements related to motor activities with those of the brain, an approach still little explored in the scientific disciplines. These discoveries can be used as first steps to establish pre-diagnostics operating as decision-making aid to the measures to be taken for a person whose autonomy could be seen threatened even before symptoms of cerebral or postural deteriorations are really observed. Moreover, they would allow to evaluate medical treatments as well as physical training in order to determine if the latter are efficient to delay the effects of aging.

Keywords: Machine Learning, functional MRI, structural MRI, Knime, aging

1. Introduction

1.1. Contexte

Dans le cadre des études en Master of Sciences en Business Administration de la HES-SO, nous sommes amenés à réaliser un travail de Master de fin de formation. Aussi, j'ai choisi de traiter la problématique de la dégénération liée au vieillissement de la population et d'étudier s'il est possible d'utiliser des méthodologies de Machine Learning (ML) afin de prédire les changements cérébraux à partir de mesures comportementales telles que celles liées à l'équilibre. Cette démarche s'inscrit dans une optique de contribution à l'amélioration des connaissances actuelles sur le sujet. En effet, la sénescence chez les seniors est l'un des sujets majeurs qui interpelle les pouvoirs publics et qui aura un impact sociétal ces prochaines années. En Suisse, l'Office fédéral de la statistique (OFS) (Schmid Botkine & Rausa-de Luca, 2008) estime que le pourcentage de la population de plus de 64 ans passera à 28% en 2050 contre 16% en 2006. Le nombre de personnes de plus de 79 ans passera de 346'000 en 2006 (5% de la population totale) à 942'000 en 2050 (12%).



Sources: OFS/ESPOP & OFS/SCENARIO

© Office fédéral de la statistique (OFS)

Figure 1- Pyramide des âges entre 2006 et 2050 selon le rapport de l'OFS de 2007

Partant de ce constat, ce travail de Master cherche à approfondir les changements structurels et fonctionnels accompagnant la vieillesse au niveau du cerveau. Il est également connu que le contrôle de la posture se détériore avec l'âge (Papegaaij, Taube, Baudry, Otten, & Hortobagyi, 2014). A l'heure actuelle, les liens entre les détériorations structurelles et fonctionnelles du cerveau et la diminution du contrôle de l'équilibre sont encore peu connus.

1.2. Question de recherche et objectifs

Ce travail tente de démontrer si le ML peut apporter une meilleure compréhension de ces deux phénomènes, à savoir les détériorations comportementales et les changements cérébraux liés à la vieillesse. Les données proviennent d'une étude menée à l'Université de Fribourg au Département de Médecine, portant sur l'entraînement de l'équilibre chez les seniors. En cas de succès, cela permettrait d'améliorer les connaissances actuelles sur liens entre l'équilibre et la dégénérescence cérébrale.

Afin de pouvoir répondre à cette problématique, les objectifs s'attelleront autour des axes suivants :

- Effectuer un état de l'art sur les méthodes utilisées pour déterminer l'équilibre et sur les changements cérébraux induits par la vieillesse.
- Définition de la meilleure approche selon l'état de l'art
- Réalisation d'un jeu de données minimum pour obtenir une baseline sur laquelle travailler
- Mise en place d'un prototype de Machine Learning basé sur la plateforme Knime pour obtenir un premier traitement des données, une première modélisation et un premier scoring permettant d'évaluer les performances de l'approche.

1.3. Périmètre et limites de l'étude

Le Machine Learning et l'étude de la sénescence sont des thématiques très vastes intrinsèquement. La présente étude combine ces deux sujets, ce qui offre par conséquent de nombreux axes possibles d'analyses et de développements. Il a fallu entre autres poser des limites à la réalisation de ce travail.

Dans un premier temps, ce travail consiste en une étude prospective basée sur des données d'une recherche expérimentale cross-sectionnelle acquise à l'Université de Fribourg. Il est donc non contrôlé, car réalisé ultérieurement à l'acquisition des données primaires. L'acquisition n'a pas été prévue dès le début avec une optique de traitement par Machine Learning et le nombre de sujets ayant participé à l'étude (35) est une limitation importante pour le traitement des données.

Dans un second temps, l'analyse des données cérébrales provenant des scanners d'imagerie par résonance magnétique (IRM) demande des compétences métiers très pointues faisant appel aux métiers de la médecine (neurologie, etc.). N'étant pas issu de ces domaines particuliers, seule une analyse très sommaire des régions cérébrales impliquées a pu être réalisée.

Enfin, étant donné que le travail est basé sur une période courte allant d'avril à août 2016, cette étude se concentra donc sur un dégrossissement du sujet afin de mettre en lumière les possibilités offertes par la combinaison du Machine Learning avec les données comportementales et cérébrales des personnes âgées.

2. Etat de l'art

L'état de l'art est divisé en six parties. La première partie traite des aspects conceptuels liés à la posturographie, la deuxième de l'IRM, la troisième présente l'imagerie motrice ainsi que l'observation d'action. La quatrième passe en revue le Machine Learning. La cinquième partie expose les articles scientifiques traitant des changements cérébraux et comportementaux liés à la sénescence ainsi que l'utilisation du Machine Learning dans ces domaines. Enfin, la dernière partie est consacrée à la synthèse de l'ensemble des aspects parcourus dans l'état de l'art.

2.1. Posturographie

La posturographie est un moyen d'évaluer les mécanismes de régulation de l'équilibration par la détermination de la trajectoire du centre de pression (en anglais center of pressure – COP) (Saint-Pierre, 2007). Pour ce faire, une plaque de force contenant des capteurs est utilisée. Ces capteurs transforment les forces appliquées en un signal électrique. Ainsi, il est possible d'obtenir l'évolution dans le temps du COP reflétant les conditions d'équilibre du sujet. Le chemin de balancement, sway path (SP) en anglais, est une mesure quantifiant la somme des longueurs entre des points consécutifs du COP durant un temps donné. Il existe différents appareils permettant de mesurer le SP tels que les plaques de force ou les accéléromètres. En effet, bien que la plaque de force soit le Gold Standard dans le domaine, elles restent coûteuses et encombrantes. C'est la raison pour laquelle des expériences sont menées avec des accéléromètres afin de pallier ces inconvénients. Toutefois, la précision de ces derniers n'est pour le moment pas satisfaisante pour suppléer la plaque de force lorsque de la précision est requise (Seimetz, Tan, Katayama, & Lockhart, 2012).




Figure 2 - Centre de pression, sujet sur une plaque de force¹




Figure 3 - Sway path¹

¹ Illustrations tirées de (Wollseifen, 2011)

Les coordonnées du COP s'obtiennent en calculant les composantes antéro-postérieure (COPap) et média-latérale (COPml) qui sont données par les formules suivantes (Duarte & Freitas, 2010):

$$COP_{ap} = \frac{-h \cdot F_x - M_y}{F_z}$$

Équation 1 - COP antéro-postérieur

$$COP_{ml} = \frac{-h \cdot F_y + M_x}{F_z}$$

Équation 2 - COP média-latéral

Avec h : hauteur du support de base sur la plaque de force (par exemple un tapis sur la plaque de force)

F(x,y,z) : force dans une des directions x,y ou z

M(x,y,z) : moment de force dans une des directions x, y ou z




Figure 4 - Plaque de force et axes de mesure²

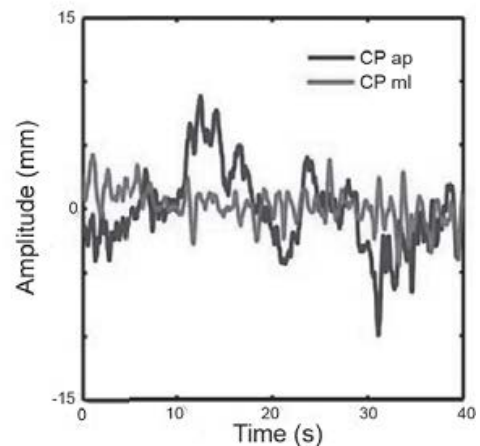


Figure 5 - Exemple de graphes de COPap et COPml²

2.2. L'IRM

L'IRM est une méthode permettant l'exploration de l'organisme en utilisant les modifications d'orientations (résonance ou vibration) de certains atomes (hydrogène) soumis à un champ magnétique intense. Cette technique est fréquemment utilisée en radiologie pour diagnostiquer des pathologies cérébrales. L'IRM est aussi largement utilisée pour la recherche scientifique afin de déterminer les bases cérébrales des comportements. On distingue deux grandes méthodes en IRM : l'IRM structurelle (sMRI) et l'IRM fonctionnelle (fMRI). L'imagerie structurelle est sensible aux propriétés biophysiques des tissus locaux du cerveau tandis que la fonctionnelle est sensible aux activités neuronales changeant avec le temps. Ces deux mesures demandent des techniques d'analyse différentes (Smith, et al., 2004). L'analyse fonctionnelle détecte les changements sanguins dans le cerveau pendant l'exécution de tâches. C'est une méthode qui a une bonne résolution temporelle, car elle se fait pendant l'activité cérébrale et permet de suivre les variations observées durant l'acquisition. L'analyse structurelle quant à elle mesure les volumes des tissus cérébraux (matière grise et blanche) ainsi que la quantité de liquide cérébro-spinal (LCS), anciennement appelé liquide céphalo-rachidien. Cette méthode est plus lente mais permet d'obtenir des informations sur l'anatomie du cerveau. En IRM, le terme voxel (contraction de volumetric pixel en anglais) est utilisé pour parler des pixels volumétriques (en 3D) du cerveau.

² Illustrations tirées de (Duarte & Freitas, 2010)




Figure 6 - Changements des matières grises et blanches après entraînement de l'équilibre³




Figure 7 – Visualisation fMRI selon trois orientations⁴

2.3. Imagerie motrice et observation d'action

L'imagerie motrice (IM), motor imagery en anglais, est l'exécution mentale d'un mouvement sans action manifeste ou sans l'activation de muscles périphériques. Dans la littérature, il a été montré que l'imagerie motrice conduit à la même activation des régions cérébrales qu'un mouvement réel (Mulder, 2007). En IM, la perspective utilisée par la personne pour imaginer peut être effectuée soit à la première personne, soit à la troisième personne. Lorsqu'il s'agit de la première personne, sa perspective peut être liée à la vue d'un contenu visuel ou à ses perceptions kinesthésiques. L'observation d'action (OA) est la réactivation interne de la représentation d'une action motrice spécifique effectuée par d'autres individus (Abbruzzese, Avanzino, Marchese, & Pelosin, 2015). L'étude menée par (Tia, et al., 2010) a montré que l'OA améliore la performance des seniors dans des tâches consécutives consistant à s'asseoir, à se lever et à se rasseoir ainsi que dans les activités de marche. (Taube, et al., 2015) ont trouvé que la combinaison de l'IM et de OA améliorent les effets de l'entraînement lorsque des tâches posturales complexes doivent être effectuées. Lors du passage au scanner IRM, les sujets doivent se positionner en décubitus dorsal et rester immobiles. Ces contraintes limitent grandement la possibilité d'effectuer des activités physiques et motrices simultanément aux acquisitions IRM. Heureusement, l'IM et l'OA permettent de parer à ces limitations puisqu'elles activent les mêmes régions cérébrales que lors de la réalisation d'un mouvement réel.

³ Illustration tirée de (Taubert, Villringer, & Ragert, 2012)

⁴ Illustration tirée de (Poldrack, Mumford, & Nichols, 2011)




Figure 8 - Activités cérébrales durant l'imagerie motrice et l'observation d'action⁵

2.4. Le Machine Learning

Les éléments fondamentaux nécessaires à la compréhension du Machine Learning sont passés en revue :

- Apprentissages supervisés et non supervisés
- Modélisation
- Evaluation des classificateurs
- Validation croisée « leave-one-out »

2.4.1. Apprentissages supervisés et non supervisés

Parmi les axes de recherche sur l'intelligence artificielle, un des axes principaux est le Machine Learning, qui englobe l'étude et le développement des modèles computationnels de processus d'apprentissage. Un des buts principaux dans ce domaine de recherche est la construction de machines capables d'améliorer leur performance avec l'apprentissage et gagner de la connaissance par elles-mêmes (Mitchell, Carbonell, & Michalski, 2012). En ML, il existe deux types d'apprentissages : supervisé et non supervisé. Basé sur leurs principales caractéristiques résumées ci-dessous (Donalek), il s'agira de s'orienter vers un apprentissage supervisé ou non en fonction du jeu de données à traiter.

⁵ Illustration tirée de (Abbruzzese, Avanzino, Marchese, & Pelosin, 2015)

| Supervisé | Non supervisé |
|--|--|
| Les données d'entraînement contiennent à la fois les attributs et les résultats désirés | Le modèle n'est pas alimenté avec des résultats connus durant la phase d'entraînement |
| Pour certains exemples les résultats sont connus et sont donnés comme paramètres au modèle pendant le processus d'apprentissage | Peut être utilisé pour regrouper les données d'entrée en classes basées uniquement sur leurs propriétés statistiques |
| La construction d'un jeu d'entraînement, de validation et de test est cruciale | Signification des clusters et labélisation |
| Les méthodes sont généralement rapides et précises | La labélisation peut être effectuée même s'il n'y a qu'un faible échantillon d'objets appartenant à la classe |
| Possibilité de généralisation : donner un résultat correct lorsqu'une nouvelle entrée dont on ne connaît pas la classe est présentée | |

Tableau 1 - Comparaison des méthodes d'apprentissages supervisés et non supervisés

2.4.2. Modélisation

Il existe un grand nombre d'algorithmes permettant d'effectuer le ML. Compte tenu du contexte et des méthodes de collectes de données, il convient de présenter uniquement les algorithmes supervisés. Les choix retenus sont systématiquement motivés par les exemples trouvés dans la littérature.

Arbres de décisions et forêt d'arbres décisionnels

Le classificateur des arbres de décisions est une des méthodologies les plus utilisées en pratique de par sa nature robuste au bruit. Cette méthode classe les instances en les arrangeant, depuis la racine de l'arbre jusqu'aux nœuds des feuilles, qui fournissent la classification des instances. Chaque nœud spécifie un test d'un attribut et chaque branche descendant à un nœud correspond à une des valeurs possibles pour cet attribut (Mitchell, Machine Learning, 1997). Cette méthodologie est particulièrement recommandée pour l'analyse de données IRM, comme lors de la détection de la maladie de Parkinson (Nair, et al., 2013). Il existe également une méthode dite « forêt d'arbres décisionnels », elle permet d'augmenter la diversité en combinant plusieurs arbres de décisions (Gashler, Giraud-Carrier, & Martinez, 2008).

K plus proches voisins

En ML, le k plus proche voisin, en Anglais k-nearest neighbour (kNN), est un des algorithmes les plus appliqués. Il consiste à assigner à un échantillon non classifié, la classification du plus proche des éléments précédemment classifiés. Pour classifier une nouvelle instance, la distance euclidienne (éventuellement avec un facteur de poids) est calculée entre l'instance et chaque instance d'entraînement. La classe de la nouvelle instance est assignée par rapport à celle présentant la plus courte distance. De façon plus générale, les k plus proches voisins sont calculés et la nouvelle instance est assignée à la classe qui est la plus présente parmi les k plus proches voisins, k étant un paramètre à choisir (Pedrycz, Succi, & Stillitti, 2016). Il existe de nombreux articles de recherches combinant kNN et données MRI comme par exemple (Vidayanathan, et al., 1995) ou (Mazzara, Velthuisen, Pearlman, Greenberg, & Wagner, 2004).

Réseaux de neurones

Cette méthodologie s'appuie sur le modèle des réseaux de neurones biologiques, comme le cerveau. Elle est composée d'un grand nombre de neurones interconnectés qui travaillent en union afin de résoudre un problème spécifique. Tout comme les humains, les réseaux de neurones apprennent par les exemples. L'apprentissage biologique nécessite des ajustements au niveau synaptique entre les neurones. Ceci est également vrai dans le

cas des réseaux de neurones artificiels (Kriesel, 2007). Dans la littérature, les réseaux de neurones ont été utilisés avec succès pour l'analyse d'images médicales (Jiang, Trundle, & Ren, 2010) ainsi que pour la classification de lésions du foie chez les rats à l'aide d'images IRM (Guo, Qiu, Bian, Kang, & Zhang, 2009).

Ci-dessous, un résumé des algorithmes retenus est présenté :

| Algorithme | Propriétés |
|------------------------------|---|
| Arbres de décisions | Modèle de décisions basé sur les attributs et valeurs |
| Forêts d'arbres décisionnels | Modèle de décisions basé sur les attributs et valeurs |
| K plus proches voisins | Basé sur l'organisation de groupes à caractères similaires (clusters) |
| Réseaux de neurones | Inspiré des réseaux de neurones biologiques |

Tableau 2 - Algorithmes retenus et leurs propriétés

2.4.3. Evaluation des classificateurs

Matrice de confusion

Lorsqu'un classificateur est choisi, il faut un outil pour pouvoir déterminer sa performance et le comparer avec un autre. Pour ce faire, la matrice de confusion semble être appropriée. En effet, elle est utilisée dans le cas d'apprentissages supervisés et indique le nombre de prédictions correctes et incorrectes du modèle comparé aux valeurs réelles. Il s'agit d'une matrice NxN où N est le nombre de classes. Chaque colonne de la matrice représente les instances prédites d'une classe tandis que les lignes représentent les instances labélisées de la classe. A partir de cette matrice, il est possible de déterminer la précision (accuracy) et le rappel (recall) (Davis & Goadrich, 2006). La précision est le nombre de classes correctes par rapport au nombre de classes correctes que possède la base alors que le rappel est le nombre de classes correctes par rapport au nombre total de classes. Ci-dessous une matrice de confusion contenant deux classes (positif et négatif) :

| | Positif prédit | Négatif prédit |
|------------------|----------------|----------------|
| Positif labélisé | TP | FN |
| Négatif labélisé | FP | TN |

Tableau 3 - Matrice de confusion

La précision et le rappel se calculent comme suit :

$$Précision = \frac{TP}{TP + FN}$$

Équation 3 – Calcul de la précision

$$Rappel = \frac{TP}{TP + FP}$$

Équation 4 - Calcul du rappel

Courbe ROC et AUC

Lors de la comparaison des classificateurs, la précision et le rappel ont une limite corrélée par l'équilibrage des classes. Afin de parer à cette limitation, la courbe « Receiver Operating Characteristic » (ROC) permet de représenter graphiquement la relation du taux de vrais positifs en ordonnée en regard du taux de faux positifs en abscisse. Historiquement, le terme ROC tire son origine de la Seconde Guerre mondiale lors de l'utilisation de radars devant permettre d'identifier les ennemis et les séparer du bruit. Dans le cas d'une classification à deux classes (0 et 1), le taux de faux positifs (FPR) est la probabilité qu'une instance soit classifiée appartenant à la classe 1 alors qu'elle appartient en réalité à la classe 0. Le taux de vrais positifs (TPR) est la probabilité qu'une instance soit classifiée appartenant à la classe 1 alors que sa vraie classe est 1. L'avantage de la courbe ROC est qu'elle est insensible à la répartition des classes. En effet, au lieu de prendre en considération toute la matrice de confusion, elle ne se base que sur une colonne à la fois, se détachant ainsi du problème de l'équilibre

des classes (Davis & Goadrich, 2006). Afin de pouvoir comparer les courbes ROC entre-elles, l'aire sous la courbe, « area under the curve » (AUC) est une valeur discrète qui peut être comparée entre les classificateurs (Bradley, 1996). Une AUC de 0.5 indique que le classificateur ne performe pas mieux qu'un classificateur aléatoire tandis qu'une AUC de 1 indique un classificateur parfait. Pour pouvoir prendre en considération une valeur AUC, il faut donc qu'elle soit supérieure à 0.5.

$$TPR = \frac{TP}{TP + FN}$$

Équation 5 – Taux de vrais positifs

$$FPR = \frac{FP}{FP + TN}$$

Équation 6 – Taux de faux positifs




Figure 9 - Courbe ROC⁶

La détermination d'une valeur assignant un score AUC comme étant bon dépend fortement du contexte et du domaine de recherche. Par exemple, en psychologie appliquée une AUC supérieure à 0.7 est considérée comme ayant un grand effet tandis que dans des domaines médicaux encore peu explorés une AUC de 0.8 est considérée comme étant bonne (Pickering, 2015). Toutefois, (Tape, 2001) propose le classement suivant pour les données biomédicales :

| AUC | Classement |
|-------------|------------|
| 0.90 – 1.00 | Excellent |
| 0.80 – 0.90 | Bien |
| 0.70 – 0.80 | Acceptable |
| 0.60 – 0.70 | Pauvre |
| 0.50 – 0.60 | Echec |

Tableau 4 - Classement des AUC selon (Tape, 2001)

⁶ Illustration adaptée de : http://gerardnico.com/wiki/data_mining/roc

Ecart-type et intervalle de confiance

L'AUC permet de représenter la probabilité qu'une instance choisie aléatoirement comme appartenant à une classe soit correctement labélisée comparativement à une instance appartenant à l'autre classe choisie elle aussi aléatoirement. Cette mesure est accompagnée de caractéristiques statiques comme décrit par (Hanley & McNeil, 1982), notamment l'écart-type, appelé standard deviation (SD) en anglais et l'intervalle de confiance, confidence interval (CI) en anglais. L'écart-type donne l'indication des bornes, $AUC \pm SD$, dans lesquelles 68% des valeurs (supposant une distribution normale) sont situées. De façon similaire, l'intervalle de confiance donne l'indication sur les bornes dans laquelle 95% des valeurs sont situées. Dans le cas d'une distribution normale, l'intervalle de confiance correspond à $AUC \pm 1.96 \times SD$.




Figure 10 - Courbe gaussienne avec SD (68%) et CI (95%)⁷

2.4.4. Validation croisée « leave-one-out »

Le processus de collecte de données peut être assez fastidieux et demander des ressources importantes, c'est la raison pour laquelle, les données recueillies sont souvent limitées. De plus, afin de pouvoir entraîner et tester un classificateur, cela demande de partager les données en un jeu d'entraînement et de validation, ce qui réduit d'autant plus les données à disposition. Lorsque les quantités de données sont limitées, il existe la méthode du « leave-one-out » pour traiter ce genre de cas. Lorsque les quantités de données sont suffisamment importantes pour être représentatives de la population, cette étape n'est généralement pas nécessaire. Le principe du « leave-one-out » repose sur le retrait d'un échantillon à la fois lors de la phase de validation. La contrepartie de cette méthodologie est qu'elle est relativement gourmande en ressources puisque le processus doit être reconduit autant de fois qu'il y a d'échantillons (Priddy & Keller, 2005).

2.5. Littérature sur la sénescence et le Machine Learning

Cette partie passe en revue les articles scientifiques publiés par la communauté médicale et informatique pour évaluer les changements cérébraux chez les personnes âgées, les détériorations comportementales ainsi que l'utilisation du ML dans ses domaines. Pour ce faire, les axes suivants sont présentés :

- Régions cérébrales impliquées dans le contrôle de l'équilibre
- Détériorations comportementales accompagnant la sénescence
- Utilisation du Machine Learning en lien avec les changements cérébraux et comportementaux chez les seniors
- Synthèse sur les régions cérébrales

⁷ Illustration tirée de (Turgeon, 2014)

2.5.1. Régions cérébrales impliquées dans le contrôle de l'équilibre

Dans leur étude, (Clausi, et al., 2009) ont cherché à mettre en évidence des changements cérébraux en analysant les différentes données collectées avec un IRM basé sur la morphométrie des voxels (voxel-based morphometry – VBM en anglais). L'objectif de cette recherche est d'analyser les anomalies cérébrales avec une lésion isolée. On y apprend que le cerebellum (cervelet en français) n'est pas uniquement rattaché au contrôle moteur mais que ce dernier influe également sur les modulations cognitives et affectives. Aussi, les liaisons cérébrales focalisées montrent des déficits comportementaux dans plusieurs domaines cognitifs comme l'indiquent les nombreuses références présentes dans l'article.

(Burciu, et al., 2013) ont mené une étude montrant que l'entraînement sensori-moteur améliore la performance chez les adultes avec des dégénérescences cérébrales et ont identifié les changements de volume de la matière grise liés à l'entraînement. Bien qu'il soit connu que le cerebellum contribue à l'apprentissage moteur, ils ont cherché à savoir si les changements observés de la performance sont dus au cerebellum ou à d'autres zones du cerveau impliquées dans le contrôle moteur et l'apprentissage. L'intérêt de l'entraînement est justifié par le fait que mises à part quelques exceptions, il n'existe pas de médicaments qui permettent de supprimer les symptômes ou freiner la lente progression des maladies cérébrales. Par conséquent, il y a un grand intérêt vers la physiothérapie et l'entraînement. Leurs résultats montrent que les améliorations en performances après entraînement de l'équilibre sont essentiellement associées à une augmentation du volume de matière grise dans le cortex prémoteur dorsal qui se projette dans le cortex moteur primaire et le cerebellum. Il est également mentionné que le cortex prémoteur dorsal est impliqué dans la planification des mouvements et les stades précoces de l'apprentissage moteur.

2.5.2. Détériorations comportementales accompagnant la sénescence

Dans leur publication, (Ilg, et al., 2009) étudient l'effet des entraînements physio-thérapeutiques sur les patients avec des dégénérescences cérébrales. Pour ce faire les données ont été relevées huit semaines avant l'entraînement, juste après et huit semaines après. Les mesures tiennent compte entre autres de la vitesse de marche et du SP. Les résultats montrent que l'entraînement améliore la coordination motrice et réduit les symptômes de l'ataxie (troubles au niveau de la coordination des mouvements volontaires). Dans leur article, (Seidler, et al., 2010) passent en revue les différences cérébrales et motrices liées à l'âge. Pour ce faire, ils se basent sur les parties structurelle et fonctionnelle du cerveau ainsi que sur les effets biochimiques. Ils observent qu'en général les personnes âgées montrent des implications plus prononcées dans les régions motrices du cerveau que celles des jeunes adultes, particulièrement dans le cortex préfrontal et dans les ganglions de la base. La littérature sur le contrôle neuronal lié aux mouvements n'a pas été développée aussi rapidement que celle liée aux fonctions cognitives mais les résultats montrent que des parallèles liés à la vieillesse entre les systèmes moteur et cognitif existent. Dans les méthodologies citées, il est mentionné que les personnes âgées montrent une augmentation du SP, mettant en évidence la limite de leur stabilité comparée aux jeunes adultes. Le volume de la matière grise est également plus petit dans cette population tandis que le LCS augmente. L'hypothèse est émise que l'atrophie du cortex moteur primaire contribue à la réduction de la vitesse des mouvements accompagnant la vieillesse. Le taux de sérotonine (neurotransmetteur) dans le putamen est inférieur chez les personnes âgées et est lié à des facultés affaiblies lors de performances cognitives. En outre, ils précisent que dans la littérature il n'a pas encore été correctement évalué s'il existe un lien entre les volumes structurels du cerveau et les mesures de la performance moteur, ce qui est justement l'objet de notre étude.

2.5.3. Utilisation du Machine Learning en lien avec les changements cérébraux et comportementaux chez les seniors

L'analyse du cerveau étant un domaine d'étude qui prend de plus en plus d'ampleur, les méthodes de ML sont devenues populaires pour classifier les données structurelles et fonctionnelles des IRM. En effet, les larges quantités de données issues des scanners se prêtent particulièrement bien au Knowledge Discovery (KD). Ainsi, (Zhang, Yan, Huang, Yang, & Huang, 2008) utilisent le ML pour détecter la perte de matière grise des patients

atteints de l'Alzheimer (Alzheimer Disease en Anglais - AD). Pour ce faire, ils utilisent l'algorithme de machines à vecteurs de support (SVM) et le comparent aux réseaux de neurones artificiels (ANN). Leurs résultats montrent que les SVM ont des meilleures propriétés de généralisation que les classificateurs basés sur l'ANN. Afin de réduire le nombre de propriétés trop importantes pour chaque sujet, une analyse des composantes principales (PCA) est appliquée. Cette dernière étape montre une légère amélioration des résultats, les facteurs limitants étant essentiellement le nombre d'échantillons trop petits et la faible corrélation entre les propriétés. Dans une optique similaire, à savoir, la détection du AD, (Saraswathi, Mahanand, Kloczkowski, Suresh, & Sundarajan, 2013) utilisent une combinaison de trois algorithmes de ML afin de détecter l'Alzheimer. Ils formulent la détection de l'AD en un problème 3 classes : normal vs très petite AD vs AD modérée, obtenant une précision avoisinant les 90%. (Murphy, Poplawsky, Vazquez, & Chan, 2016) ont travaillé sur des données fMRI issues du bulbe olfactif des rats afin de déterminer si le ML permettait de mieux déterminer les zones d'intérêts du cerveau comparé au VBM. Ils ont trouvé que le ML permettait soit une meilleure ou équivalente détection comparée à la méthode classique basée utilisant le VBM. Enfin, (Clark, et al., 2016) utilisent le ML pour établir le lien entre la fluidité verbale et la AD. Ils utilisent les données sRMI provenant des régions d'intérêts (Region of Interest en anglais – ROI) de l'hippocampe, ventricule et matière grise afin d'alimenter leur modèle. Plusieurs méthodes de ML sont utilisées et sont comparées entre-elles à l'aide de la courbe ROC et de l'AUC. Etant donné le petit échantillon de la population à disposition, la méthode du « leave-one-out » a été utilisée.

2.5.4. Synthèse sur les régions cérébrales

Au vu de la littérature parcourue, les régions cérébrales citées sont nombreuses. Chacune d'elles a des caractéristiques propres ou partagées en liaison avec le contrôle de l'équilibre et la vieillesse. Ainsi, le paragraphe suivant fait une synthèse des régions potentiellement intéressantes dans le cadre de ce travail.




Figure 11 - Régions cérébrales fonctionnelles⁸

Brain stem

Le tronc cérébral (brain stem) joue un rôle important dans la régulation de l'équilibre. La moelle épinière ainsi que le tronc cérébral permettent de compenser les perturbations de l'équilibre en utilisant des mécanismes de réflexe. Dans cette région du cerveau, les informations de l'appareil vestibulaire, des systèmes proprioceptifs et visuels convergent et sont intégrés dans les commandes du cortex moteur (Gollhofer, Taube, & Nielsen, 2013). En inhibant les activités du tronc cérébral vers la moelle épinière, (Vinay, et al., 2005) ont montré que les mécanismes du contrôle postural et moteur sont réduits.

⁸ Illustration tirée de : <http://humanbiologyandhealth.blogspot.ch/p/nervous-co-ordination.html>

Cerebellum

Le cervelet (cerebellum) est impliqué dans l'ajustement des mouvements agonistes et antagonistes, ainsi que dans la coordination de mouvements successifs (Diener & Dichgans, 1992). Cette région contient des fonctions importantes du contrôle des yeux et des muscles axiaux. La détérioration de cette structure cause par conséquent des détériorations de l'équilibre et de la marche. En général, le cervelet semble être crucial pour la mémorisation et la compensation des réactions dans des situations de perturbation. Par conséquent, les patients avec des lésions au cervelet sont généralement incapables de corriger leur mouvement dans ce genre de situation (Gollhofer, Taube, & Nielsen, 2013). En outre, (Morton & Bastian, 2007) déduisent par observation que le cervelet d'une personne saine « apprend » des erreurs de mouvements et développe une forme différente de réaction posturale en ajustant sa boucle de contrôle anticipatrice.

Cortex moteur (M1, PMC et SMA)

Le cortex moteur est divisé en trois régions qui sont le cortex moteur primaire (M1), le cortex pré-moteur (PMC) et l'aire motrice supplémentaire (SMA). Le M1 tient son nom du fait que les stimulations électriques pour engendrer des mouvements sont inférieures comparées aux autres régions corticales (Riehle & Vaadia, 2004). Une des fonctions principales du M1 est de contrôler les mouvements volontaires des jambes, des bras et de la tête (Sanes & Donoghue, 2000). Les régions du PMC sont activées lorsque de nouveaux programmes moteurs sont initiés ou lorsque des programmes moteurs appris sont modifiés. Les neurones du PMC sont activés en anticipation d'un mouvement et semblent être impliqués dans la génération d'un mouvement en mémoire qui demande un timing précis. La SMA est impliquée dans l'exécution de contrôles en situation de réponses conflictuelles. Elle semble également être engagée dans les processus d'acquisition et de rappel des programmes moteurs (Clark, Boutros, & Mendez, 2010).

PFC

Le cortex pré-frontal (PFC) est engagé dans le contrôle cognitif et dans l'aptitude à orchestrer les pensées et les actions en accord avec des buts internes. Il est connu pour être la région néocorticale la plus développée chez les primates, réputés pour leurs répertoires de comportements riches et flexibles. Le PFC n'est pas un élément critique pour les tâches simples et automatiques (s'orienter vers un bruit). Il intervient plutôt dans les tâches où les comportements doivent être guidés par des états internes ou par des intentions. Ce sont des situations où la modélisation entre les entrées sensorielles, les pensées et les actions est faiblement établie comparée à celles déjà connues (Miller & Cohen, 2001). (Taubert, et al., 2010) ont montré que le volume de matière grise augmente dans le PFC lorsque les sujets s'améliorent à une tâche d'équilibre après six semaines d'apprentissage.

S1

Le cortex somatosensoriel primaire est situé dans le gyrus postcentral et fait partie d'une des quatre aires du cortex somesthésique. C'est la partie principale qui reçoit les informations sensorielles. Toutefois, plusieurs études avec des singes (Zhou & Fuster, 1996), (Super, Spekreijse, & Lamme, 2001) ont montré que cette région était impliquée dans la mémorisation de tâches tactiles ou visuelles. (Harris, Miniussi, Harris, & Diamond, 2002) ont montré que S1 n'est pas uniquement impliqué dans le traitement des informations sensorielles mais sert également comme site de dépôt de transition pour les informations sur le travail de la mémoire.

Ganglions de la base et putamen

Les ganglions de la base (Basal Ganglia – BG) jouent un rôle important dans les détériorations de la posture. Par exemple, chez les patients atteints de la maladie de Parkinson, une dysfonction au niveau du BG est associée à une posture instable, à des chutes fréquentes et une incapacité à la marche (Nieuwenhuijzen, Horstink, Bloem, & Duysens, 2005). De plus, il est connu que les BG améliorent le contrôle de la posture à travers un mécanisme d'adaptations constantes aux changements environnementaux. Il a également été montré que des lésions aux BG sont accompagnées par une détérioration de la capacité à prendre en compte les informations sensorimotrices (Gollhofer, Taube, & Nielsen, 2013). Ce dysfonctionnement pourrait expliquer pourquoi les patients atteints de la maladie de Parkinson ne sont pas en mesure d'être conscients de l'oscillation de leur

propre corps et sont surpris de se voir osciller lorsqu'ils sont placés face à un miroir (Visser & Bloem, 2005). Le putamen fait partie de la portion externe des ganglions de la base et est connu pour ses fonctions de la régulation des mouvements volontaires (Bernardi, Carpentier, Di Chiara, Morelli, & Stanzione, 2012). En outre, (DeLong & Wichmann, 2007) ont montré que le putamen joue un rôle important chez les patients atteints de la maladie de Parkinson causant une inhibition excessive du thalamus.

2.6. Synthèse sur l'état de l'art

Au travers de l'état de l'art, plusieurs concepts ont été passés en revue. Le présent paragraphe a pour but de dresser une vue d'ensemble de ces concepts. La posturographie est une technique de mesure permettant d'obtenir le COP à l'aide d'une plaque de force. Le COP est une mesure indicative sur la capacité d'équilibre d'une personne. L'IRM permet d'explorer le cerveau grâce au champ magnétique de la machine. Il existe deux méthodes de mesures qui sont la structurelle (sMRI) et la fonctionnelle (fMRI). sMRI donne le volume de matière grise, blanche et le LCS tandis que le fMRI est une mesure de l'activité cérébrale. L'imagerie motrice et l'observation d'action permettent d'activer les mêmes régions cérébrales qu'une action physique. Ils ont l'avantage de pouvoir être effectués dans les scanners IRM où les contraintes de placement forcent les sujets à être immobiles. Le Machine Learning est une méthode computationnelle basée sur l'intelligence artificielle. Elle permet de découvrir de la connaissance au travers de ses algorithmes d'apprentissage et de classification. Afin de pouvoir comparer la performance des différents algorithmes, l'AUC est la méthode la plus couramment utilisée dans la pratique. Pour effectuer du ML, il faut une quantité de données relativement importante. Dans les cas où ces données sont peu nombreuses, il est toutefois possible d'essayer de les utiliser grâce à la validation croisée « leave-one-out ». La revue de la littérature scientifique montre que des équipes dans le monde travaillent sur le sujet des régions cérébrales impliquées dans le contrôle de l'équilibre, des détériorations comportementales accompagnant la vieillesse ainsi que sur l'utilisation du ML avec des données cérébrales. Toutefois, à notre connaissance, aucune équipe n'a travaillé jusqu'à présent sur le lien entre la performance motrice et les données cérébrales que ce soit avec ou sans l'aide du ML. Cette absence de recherche est également constatée par (Seidler, et al., 2010). Le présent travail s'annonce donc être une première dans le domaine, car il utilise des méthodologies modernes pour tenter de répondre à une problématique pas encore abordée par la communauté scientifique.

3. Méthodologie

3.1. Comparaison des méthodologies de découverte de connaissance

Afin de conduire des analyses en Data Mining (DM) pour découvrir de la connaissance (KD), il est utile de se baser sur une méthodologie permettant de guider la démarche et arriver le plus rapidement possible aux résultats escomptés. En effet, les données variées, en volume important, nécessitent de définir clairement un modus operandi précis. Pour ce faire, (Fayyad, Piatetsky-Shapiro, & Smyth, 1996) proposent de suivre le processus générique suivant appelé Knowledge Discovery in Databases (KDD) :

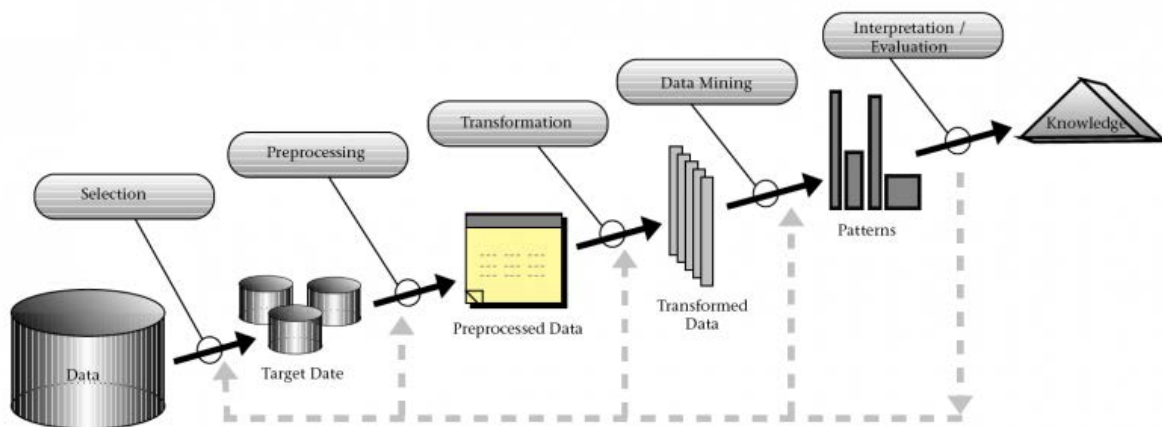


Figure 12 - Processus de découverte de connaissance⁹

Le KDD se résume en 5 étapes :

| Numéro | Nom | Description |
|--------|---------------------------|--|
| 1 | Sélection | Création des données ou d'une sous-catégorie de données sur lesquelles la découverte va s'établir |
| 2 | Pré-traitement | Nettoyage des données pour obtenir des données consistantes |
| 3 | Transformation | Transformation des données en utilisant la réduction dimensionnelle ou des méthodes de transformations |
| 4 | Data Mining | Recherche de modèles en adéquation avec les objectifs de DM |
| 5 | Interprétation/évaluation | Interprétation et évaluation des modèles trouvés |

Tableau 5 - Etapes du KDD

⁹ Image tirée de (Fayyad, Piatetsky-Shapiro, & Smyth, 1996)

Selon (Azevedo & Santos, 2008), le KDD peut être perçu comme un processus générique dont SEMMA (acronyme de Sample, Explore, Modify, Model, Assess) et CRISP-DM (acronyme de Cross Industry Standard Process for Data Mining) sont des implémentations. En outre, ils proposent de résumer leurs principales caractéristiques sous la forme suivante :

| KDD | SEMMA | CRISP-DM |
|---------------------------|----------------|---------------------------|
| Pré KDD | ----- | Compréhension métier |
| Sélection | Echantillonner | Compréhension des données |
| Pré-traitement | Explorer | |
| Transformation | Modifier | Préparation des données |
| Data Mining | Modéliser | Modélisation |
| Interprétation/évaluation | Evaluer | Evaluation |
| Post KDD | ----- | Déploiement |

Tableau 6 - Correspondances entre KDD, SEMMA et CRISP-DM¹⁰

D'après le tableau ci-dessus, il apparaît clairement que CRISP-DM est l'implémentation la plus complète de KDD. En effet, SEMMA ne tient pas compte des étapes de pré et post KDD. La partie pré KDD, à savoir la compréhension métier, est une phase cruciale de notre projet qui ne peut être ni contournée, ni omise. Par conséquent, CRISP-DM est la méthodologie qui sera retenue dans le cadre du présent travail. En plus d'être complet, il présente l'avantage d'être reconnu majoritairement par des experts du domaine (Shearer, 2000) tels que Daimler (constructeur automobile allemand), NCR (fabricant américain de composants électroniques) ou encore SPSS (logiciel d'analyse statistique).

¹⁰ Traduite de (Azevedo & Santos, 2008)

3.2. Méthodologie adoptée – CRISP-DM

Le processus CRISP-DM s'effectue en 6 phases (Chapman, et al., 2000). Les phases 1 à 5 suivent un processus itératif jusqu'à l'obtention d'un modèle satisfaisant. La phase 6 n'est effectuée qu'en fin de processus. Ces phases peuvent être schématisées à l'aide de la figure ci-dessous (les doubles flèches indiquent des relations étroites entre les phases) :




Figure 13 - Phases itératives du modèle CRISP-DM¹¹

1. Compréhension métier

La phase initiale se concentre sur la compréhension des objectifs du projet ainsi que sur les exigences d'après une vision métier. Ensuite, il s'agit de transposer ces connaissances en la définition d'un problème de DM et d'établir un plan préliminaire permettant d'atteindre les objectifs.

Application au projet : cette phase est couverte par le chapitre 2 Etat de l'art.

2. Compréhension des données

La phase de compréhension des données commence par un jeu de données initial suivi d'activités permettant de s'appropriier les données et d'identifier les problèmes de qualité de données. C'est ici que l'on peut entrevoir les perspectives et/ou détecter les sous-ensembles afin d'établir des hypothèses concernant les informations cachées.

Application au projet : cette phase est couverte par le chapitre 4.1 Données initiales.

¹¹ Image tirée de : <http://www.kdnuggets.com/2016/08/data-science-automation-debunking-misconceptions.html>

3. Préparation des données

La phase de préparation des données couvre toutes les activités nécessaires à la construction d'un jeu de données final (celles qui seront utilisées pour alimenter le modèle) à partir de données brutes. Les tâches de préparations sont susceptibles d'être répétées aussi souvent que nécessaire et sans cadre défini. Ces tâches comprennent : tableaux, attributs de la sélection, transformation et nettoyage.

Application au projet : cette phase est couverte par le chapitre 4.2 Préparation des données ainsi que par les itérations des chapitres 4.3 à 4.8.

4. Modélisation.

Dans cette phase, plusieurs techniques de modélisation sont sélectionnées et appliquées. Leurs paramètres sont calibrés afin d'obtenir des valeurs optimales. A titre d'exemple, un problème peut être analysé par des modèles différents de DM. Aussi, certaines techniques requièrent un formatage particulier des données, raison pour laquelle il est souvent nécessaire de revenir à la phase de préparation des données.

Application au projet : cette phase est couverte par les itérations des chapitres 4.3 à 4.8.

5. Evaluation

A ce stade, le modèle construit apparaît avoir une haute qualité d'une perspective de l'analyse des données. Avant de procéder au déploiement final du modèle, il est important de l'évaluer minutieusement et de revoir les étapes exécutées pour obtenir ce dernier afin de s'assurer que le modèle réponde correctement aux objectifs métiers. Le but majeur de cette étape est de déterminer s'il subsiste un besoin métier qui n'a pas été suffisamment pris en compte. A la fin de cette phase, une décision sur l'utilité des résultats du DM doit être prise.

Application au projet : cette phase est couverte par les itérations des chapitres 4.3 à 4.8 ainsi que par le chapitre 5.1 Synthèse des résultats obtenus.

6. Déploiement

La création du modèle n'engendre généralement pas la fin du projet. Malgré une augmentation de la connaissance des données, les informations acquises doivent être organisées et présentées de sorte que le client puisse l'utiliser. Cela implique souvent une application utilisable au sein de l'organe de décision de l'entreprise. En fonction des exigences, la phase déploiement peut être aussi simple que la génération d'un rapport ou aussi complexe que la mise en place d'un processus de DM reproductible au sein de l'entreprise.

Application au projet : pour des raisons de limitation temporelle, le déploiement ne sera pas effectué dans le cadre de ce projet.

3.3. Acquisition des données

Les données sont issues d'une étude menée à l'Université de Fribourg qui porte sur l'entraînement de l'équilibre en combinant observation et imagerie motrice. On y retrouve également une analyse sur l'évaluation des changements comportementaux et leurs adaptations neuronales sous-jacentes. De l'ensemble des données générées par cette étude, deux sous-ensembles ont été retenus. Le premier comporte les mesures comportementales (contrôle de l'équilibre) et le second des mesures IRM sur le cerveau. Pour ce faire, 35 sujets seniors âgés entre 65 et 80 ans (moyenne : 70.9 ans, écart-type : 4.5 ans) ont effectué une tâche d'équilibre sur une plaque de force qui mesure les déplacements du centre de pression, permettant d'obtenir le chemin de balancement (SP). Ces mêmes sujets ont également passé des tests avec un scanner IRM avec lequel des données fonctionnelles et structurelles sur le cerveau ont été recueillies.

3.3.1. Mesures comportementales

La mesure de l'équilibre est effectuée à l'aide d'une plaque de force. Les sujets se positionnent dessus pieds nus et doivent se tenir sur la jambe droite. Une étape de familiarisation sans mesure a été effectuée pendant 20 secondes. Puis la mesure est effectuée pendant 15 secondes durant lesquelles les forces ainsi que les moments de force dans les 3 directions (x,y et z) ont été enregistrés. Ces données permettent de calculer le sway path. Cette mesure est répétée 2 fois. Le nombre de fois où le sujet a dû poser son pied gauche a également été relevé. Les valeurs finales retenues sont les moyennes des deux essais (pour le sway path et le nombre de fois où le pied a été posé). Les signaux ont été enregistrés avec une fréquence d'échantillonnage de 100 Hz.

Voici un extrait du fichier de base de travail :

| Subject | Sway | Faults |
|---------|-----------|--------|
| 2 | 121.12 | 0 |
| 3 | 154.201 | 0 |
| 4 | 197.3972 | 1 |
| 5 | 206.29105 | 4 |
| 6 | 102.3312 | 0 |
| 7 | 207.005 | 3 |
| 8 | 68.627 | 0 |

Figure 14 - Données brutes des mesures comportementales

3.3.2. Mesures IRM

Lors de l'examen en scanner, des images mettant en scène des personnes effectuant des exercices d'équilibre ont été projetées sur un écran. Trois conditions ont été testées (pour les photos, voir annexe 10.2 Extraits vidéos des conditions AOP et AOS) :

- 1) regarder la vidéo et observer activement une tâche d'équilibre dynamique (AOP)
- 2) regarder la vidéo et observer activement une tâche d'équilibre statique (AOS)
- 3) regarder la vidéo, sans se représenter quoi que ce soit (condition de repos)

Les données IRM ont été acquises grâce à un scanner de 3 Teslas (Discovery MR750; GE Healthcare, Waukesha, WI) avec une bobine standard de 32 canaux. Les participants avaient leur tête positionnée sur un coussin en mousse à mémoire de forme afin d'atténuer les mouvements de tête. Les stimulus visuels étaient présentés sur écran à cristaux liquides à 60Hz avec une résolution de 640x480 pixels (3200 NNL liquid crystal display (LCD) Monitor, NordicNeuroLab, Bergen, Norvège) Les paramètres d'acquisition utilisés sont présentés dans le tableau ci-dessous:

| Acquisitions structurales | Acquisitions fonctionnelles |
|--|---|
| Scans anatomiques pondérés en T1 | Images planaires écho pondérées en T2 |
| Séquence FSPGR BRAVO | Contraste dépendant du taux d'oxygénation du sang |
| Taille des voxels : 0.86x0.86x1 mm | Orientation axiale des tranches |
| Taille de la matrice acquise: 256x256 | Acquisitions séquentielles ascendantes |
| Champ de vision : 22 cm | Taille des voxels : 2.3x2.3x3 mm |
| Nombre de tranches : 276 | Taille de la matrice acquise : 96 x 96 |
| Temps de répétition (TR) : 7300 ms | Champ de vision : 22 cm |
| Temps d'écho (TE) : 2.8 ms | Nombres de tranches : 37 |
| Angle de bascule : 9° | Espacement inter-tranche : 0.2 mm |
| Facteur d'accélération d'images parallèles : 1.5 | Temps de répétition : 2000 ms |
| Avec correction d'intensité SCIC | Temps d'écho : 30 ms |
| | Angle de bascule : 85° |
| | Facteur d'accélération d'images parallèles : 2 |

Tableau 7 - Paramètres et traitements d'acquisition des données IRM

3.4. Classification du type de travail

Les données primaires obtenues proviennent d'une recherche expérimentale cross-sectionnelle dont l'objectif est d'obtenir des données quantitatives. Le présent travail est une analyse prospective de ces données, car elle intervient avant la mise en production des algorithmes éventuels, qui seront utilisés pour faire le lien entre l'équilibre et les détériorations cérébrales. Il est non contrôlé étant donné qu'il se produit ultérieurement à l'acquisition.

Ce travail suit un processus de raisonnement à la fois déductif et inductif. En effet, la méthodologie CRISP-DM permettra de traiter le problème de façon générale et de faire des itérations menant de plus en plus au particulier, conformément à la logique déductive. Les résultats obtenus en fin de travail seront utilisés de façon inductive afin de pouvoir en faire une généralisation employable par les spécialistes du domaine de la neurologie et de la sénescence (Brink, Van der Walt, & Van Rensburg, 2006).

3.5. Plateforme de Machine Learning

Il existe un grand nombre d'outils permettant d'effectuer le DM et le ML. Parmi, la pléthore des plateformes possibles, Knime dans sa version 3.1.2 a été retenu pour différentes raisons. Elle présente l'avantage d'être gratuite et possède intrinsèquement un bon nombre de modules et d'extensions facilitant l'exploration et le forage des données. En outre, la communauté des utilisateurs Knime est très active et attentive aux problèmes et questions des utilisateurs de ce logiciel à travers son forum d'entre-aide et les mises à jour régulières. Ces avantages font que Knime se hisse en 3^{ème} position des logiciels d'analyse des données utilisés dans la recherche académique (Muenchen, 2015), juste après Python et R. Toutefois, il est important de mentionner que Knime possède des nœuds avec lesquels il est possible d'intégrer du code Python ou R. L'avantage principal étant que Knime facilite le travail du Data Analyst (DA) à travers une interface graphique plus intuitive que du code logiciel pur.




Figure 15 - Progression des articles académiques par outil d'analyse des données¹²

¹² Source : <http://r4stats.com/2015/03/30/fastest-growing-analytics-2015/>

4. Analyse et développement

Ce chapitre se base sur la méthodologie CRISP-DM afin de mener les étapes de préparation des données, de modélisation et d'évaluation. Conformément à cette méthodologie, diverses itérations sont menées afin de raffiner les résultats au fur et à mesure de l'avancement du traitement des données.

4.1. Données initiales

4.1.1. Données sur l'équilibre

Les données comportementales sont basées sur la mesure de l'équilibre à l'aide du sway path. La boîte à moustache (boxplot en anglais) est utilisée afin de pouvoir obtenir une meilleure représentation de la distribution du SP au sein des sujets, dont les caractéristiques principales sont exposées ci-dessous :

| Moyenne | Médiane | Ecart-type | Min | Max |
|----------|----------|------------|---------|----------|
| 124.5 mm | 109.1 mm | 50.6 mm | 60.3 mm | 270.3 mm |

Figure 16 - Statistiques sur le sway path

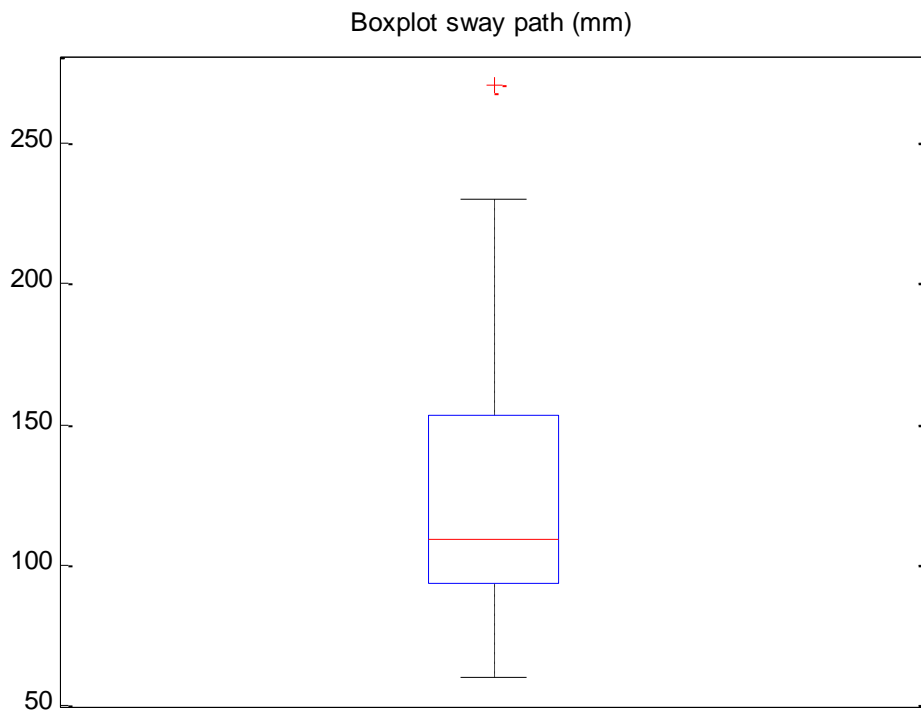


Figure 17 - Boxplot sur les données relatives à l'équilibre

La moyenne étant supérieure à la médiane, cela signifie que le jeu de données est concentré sur les valeurs basses.

4.1.2. Données sur l'IRM

Les données provenant du scanner IRM sont traitées avec le logiciel smp12¹³ reconnu par la communauté de neuro imagerie. Ce logiciel est un module complémentaire du logiciel Matlab¹⁴. Les fichiers de sortie smp12 ont été convertis au format « Comma-Separated Values » (CSV) afin de pouvoir les exploiter avec Knime. Nous avons à disposition des données structurelles et fonctionnelles du cerveau.

IRM fonctionnel

Etant donné que les mesures fonctionnelles sont basées sur des niveaux d'activations cérébrales, il convient d'établir au préalable une ligne de base (baseline). Pour ce faire, nous utilisons les comparaisons suivantes (voir également 3.3.2 Mesures IRM) :

- AOP-Repos : L'état de repos sert de niveau de base. Les niveaux d'activation durant le repos sont soustraits des niveaux d'activations lors de l'observation active d'une tâche d'équilibre dynamique.
- AOP-AOS : Les activités cérébrales durant l'observation de la tâche d'équilibre statique sont utilisées comme niveaux de base. Cette baseline est soustraite des niveaux d'activations cérébrales durant l'observation de la tâche d'équilibre dynamique.

Un exemple de fichier fMRI :

| D Col0 | D Col1 | D Col2 | D Col3 | D Col4 | D Col5 | D Col6 | D Col7 | D Col8 | D Col9 | D Col10 | D Col11 | D Col12 | D Col13 |
|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|---------|---------|---------|---------|
| -0.242 | -0.042 | 0.124 | -0.024 | -0.223 | -0.444 | -0.639 | 0.245 | -0.34 | -0.685 | -0.804 | -0.718 | -0.71 | -0.887 |
| -0.155 | 0.03 | -0.677 | -0.562 | -0.427 | -0.352 | -0.291 | -0.201 | -0.215 | -0.233 | -0.207 | -0.106 | -0.111 | -0.179 |
| 0.717 | 0.735 | 0.598 | 0.44 | 0.376 | 0.355 | 0.309 | 0.451 | 0.418 | 0.345 | 0.267 | 0.191 | 0.415 | 0.318 |
| 0.55 | 0.486 | 0.37 | 0.511 | 0.612 | 0.66 | 0.651 | 0.647 | 0.672 | 0.622 | 0.559 | 0.512 | 0.59 | 0.483 |
| -0.466 | -0.81 | -0.149 | -0.342 | -0.587 | -0.799 | -0.899 | -0.435 | -0.787 | -0.993 | -1.058 | -0.993 | -1.018 | -1.156 |
| -0.147 | -0.003 | 0.132 | 0.163 | 0.186 | 0.197 | 0.203 | 0.194 | 0.144 | 0.117 | 0.129 | 0.18 | 0.081 | 0.067 |
| -0.29 | -0.392 | 0.108 | -0.056 | -0.235 | -0.349 | -0.385 | -0.255 | -0.328 | -0.343 | -0.317 | -0.239 | -0.298 | -0.274 |
| 0.334 | 0.283 | 0.048 | -0.057 | -0.087 | -0.056 | 0.012 | -0.077 | -0.081 | -0.026 | 0.02 | 0.011 | -0.053 | 0.002 |
| -1.005 | -0.705 | -1.31 | -1.133 | -0.951 | -0.848 | -0.729 | -0.934 | -0.857 | -0.751 | -0.626 | -0.553 | -0.776 | -0.71 |
| -0.102 | -0.117 | 0.345 | 0.275 | 0.183 | 0.106 | 0.098 | 0.26 | 0.174 | 0.141 | 0.137 | 0.124 | 0.183 | 0.146 |
| 0.291 | 0.375 | 0.527 | 0.452 | 0.295 | 0.144 | 0.055 | 0.31 | 0.154 | 0.093 | 0.103 | 0.079 | 0.145 | 0.166 |

Figure 18 - Extrait d'un fichier fMRI

Chaque ligne représente un sujet et chaque colonne contient les résultats par voxel. Des fichiers séparés sont générés pour les conditions AOP-Repos et AOP-AOS. Les valeurs observées correspondent aux coefficients à appliquer aux mesures afin de les faire correspondre au modèle linéaire selon (Friston, et al., 1994).

IRM structurel

Les fichiers contenant les données structurelles du cerveau se présentent sous forme de fichier CSV contenant le volume de matière grise (volume 1), le volume de matière blanche (volume 2) ainsi que le volume de LCS (volume 3). Chaque fichier se trouve dans un dossier nommé avec l'identification du participant.

| D Volume1 | D Volume2 | D Volume3 |
|-----------|-----------|-----------|
| 0.006 | 0.007 | 0.01 |

Figure 19 - Exemple de fichier sMRI

Les valeurs contenues dans ce fichier sont des coefficients qui correspondent aux facteurs à appliquer (appelé Jacobiens) aux trois volumes pour qu'ils rentrent dans le cerveau normalisé de référence. La référence est créée sur la base de tous les participants à l'aide de l'algorithme DARTEL (Ashburner, 2007).

¹³ <http://www.fil.ion.ucl.ac.uk/spm/software/>

¹⁴ Matlab est un logiciel développé par MathWorks permettant d'effectuer des calculs numériques.

4.1.3. Vue d'ensemble

Les données IRM ont été traitées par régions d'intérêts (ROI) basées sur les éléments de la littérature (cf. 2.5.4 Synthèse sur les régions cérébrales). Ces ROI sont disponibles à la fois pour les données fMRI et sMRI. Les données initiales se présentent sous la forme suivante :

| Type d'acquisition | Détails | Nombre de sujets | Zones du cerveau |
|--------------------|--------------------------|------------------|-------------------------------------|
| Comportementale | Sway path | 35 | Entier |
| Cérébrale fMRI | AOP – Repos AOP – AOS | 33 | M1 Cerebellum Putamen |
| Cérébrale sMR | Volume des tissus et LCS | 31 | SMA S1 PFC Brainstem BG |

Tableau 8 - Vue d'ensemble du jeu de données initial

Le nombre de sujets mesuré diffère entre les trois types d'acquisitions dû au fait que certains sujets ont abandonné l'expérience durant sa réalisation ou parce que certains sujets ne peuvent pas utiliser un IRM, au regard des critères d'exclusion (cf. annexe 10.1 Critères d'exclusion pour la participation à l'étude) liés au fonctionnement même de la machine (composés ferromagnétiques, pacemaker ou à cause de facteurs psychologiques tels que la claustrophobie).

4.2. Préparation des données

4.2.1. Données comportementales

Un histogramme a été tracé afin de permettre une bonne visualisation de la distribution du sway path. Basé sur cet histogramme, un seuil a été placé à la valeur 150 mm afin de classer la population en bon et mauvais équilibre. Le choix du seuil est validé par une corrélation de 0.72 entre un équilibre jugé mauvais et le fait qu'ils aient dû poser le pied (perte de l'équilibre) lors de la mesure. Cela montre que la méthode basée sur le seuil est une bonne première approche. Une méthode plus robuste pour établir la classification serait de combiner le sway path avec le nombre de fois où le pied a dû être posé en pondérant chacun des facteurs par un poids. Etant donné que le but ici est de se rapprocher de la décision d'un spécialiste médical, l'approche retenue est jugée suffisante pour ce premier jeu de données. La méthode de sélection basée sur un seuil, « Threshold based measurement », est une approche couramment utilisée dans le domaine scientifique.

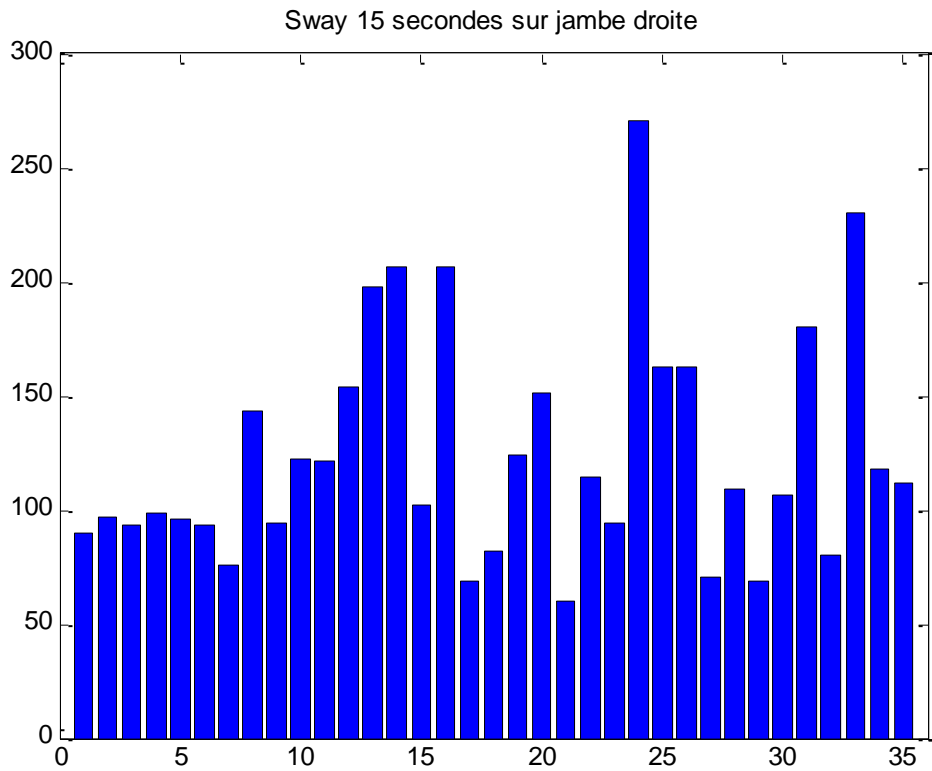


Figure 20 - Histogramme représentant la répartition des sway paths en mm entre les sujets

$$\begin{aligned}
 & \text{si } \textit{sway path} > 150 \textit{ mm} \\
 & \quad = 0 \textit{ mauvais équilibre}
 \end{aligned}$$

Équation 7 - Classification mauvais équilibre

$$\begin{aligned}
 & \text{si } \textit{sway path} \leq 150 \textit{ mm} \\
 & \quad = 1 \textit{ bon équilibre}
 \end{aligned}$$

Équation 8 - Classification bon équilibre

Un extrait du résultat de cette étape est représenté ci-dessous :

| S Subject... | Class |
|--------------|-------|
| S45 | 1 |
| S47 | 1 |
| S48 | 1 |
| S49 | 1 |
| S50 | 1 |
| S51 | 1 |
| S52 | 1 |
| S54 | 1 |
| S56 | 1 |
| S58 | 1 |
| S2 | 1 |
| S3 | 0 |
| S4 | 0 |

Figure 21 - Extrait de classification de l'équilibre par sujet

Les classificateurs en ML sont sensibles à la répartition des classes (Provost, 2000). Pour pouvoir traiter efficacement les problèmes de déséquilibre, il est important de visualiser la répartition des classes. L'histogramme ci-dessous, confirme l'analyse de la Figure 17 - Boxplot sur les données relatives à l'équilibre et montre un déséquilibre entre les sujets classifiés comme ayant un bon équilibre et ceux classifiés avec un mauvais équilibre. Il faudra donc veiller à utiliser l'AUC qui est insensible à la répartition des classes afin de comparer les classificateurs.




Figure 22 - Représentation de l'équilibre des classes

4.2.2. Nettoyage et préparation des données fMRI

Les données fMRI sont sous la forme de fichier de données Matlab (.mat) contenant une zone particulière du cerveau pour tous les sujets. Une première étape a été de transformer ces fichiers au format CSV, ce qui facilite leur exploitation par Knime. Afin de pouvoir obtenir des fichiers de travail pour le ML, il convient de nettoyer et de préparer les bases de données en vue des flux d'apprentissage et de classification dans Knime. Pour des raisons de simplification d'analyse, le choix a été retenu de créer une base de données par ROI. En créant cette base de données, une colonne avec les noms des participants anonymés¹⁵ est ajoutée. En effet, lorsque des données sont transmises à des tiers, il est important d'éviter de pouvoir identifier la personne en combinant les informations (Confédération suisse (OFS), 2016). Ensuite, il s'agit d'utiliser le fichier contenant tous les sujets avec leur classification. Etant donné que tous les sujets dont l'équilibre a été mesuré n'ont pas pu participer aux tests IRM (à cause des critères d'exclusion et de sécurité), il faut parcourir le fichier contenant la classification afin de rajouter cette dernière au fichier IRM. Ainsi, les données sont présentées sous une forme exploitable par Knime : un tableau dont les colonnes représentent les attributs et les lignes les instances. Une colonne supplémentaire doit contenir sous forme de chaîne de caractères le nom de la classe. Ces étapes sont schématisées ci-dessous :

¹⁵ Nous faisons ici la différence entre anonymiser et anonymiser. Anonymiser consiste à rendre anonyme de façon irréversible tandis que anonymiser est réversible, selon <https://fr.wiktionary.org/wiki/anonymiser>

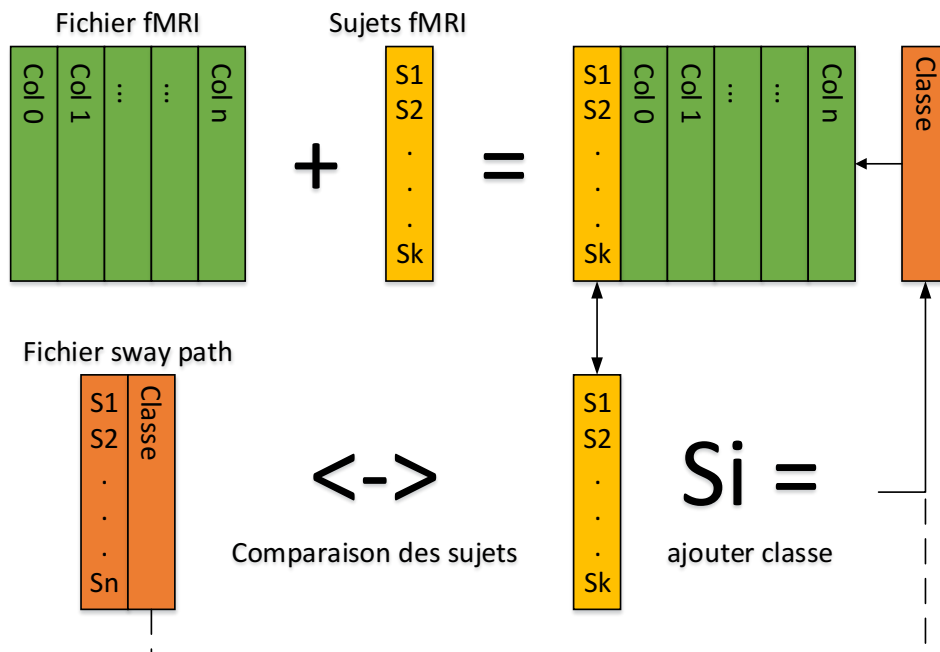


Figure 23 - Préparation et nettoyage des données fMRI en vue du ML

Le flux suivant est la représentation du schéma de principe ci-dessus, transposé dans Knime :

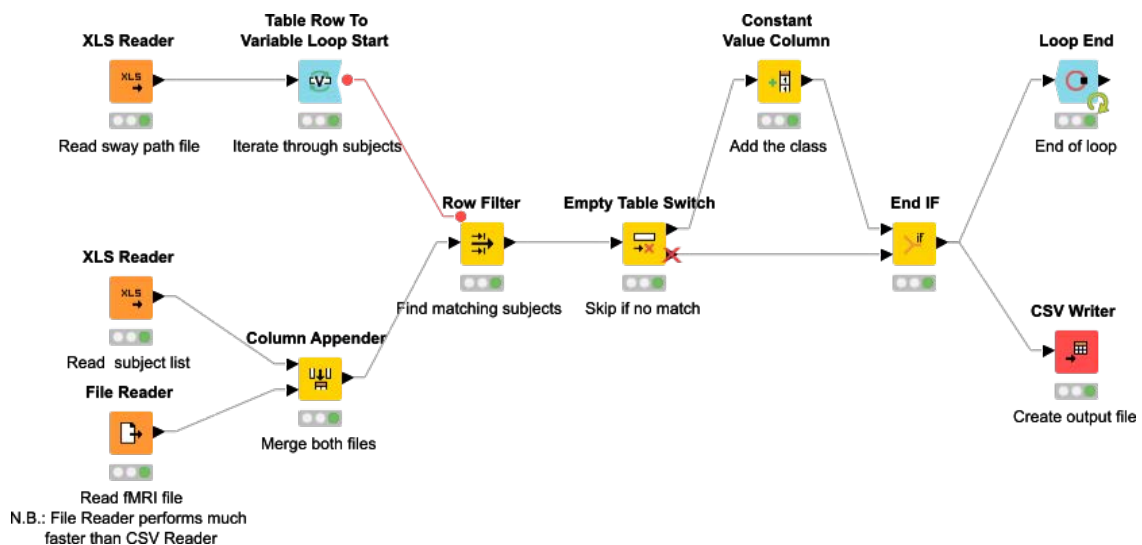


Figure 24 - Flux Knime de préparation des données fMRI

4.2.3. Nettoyage et préparation des données sMRI

Les données sMRI sont organisées par dossier. Chaque dossier est labélisé par l'identifiant du sujet (S0 à Sn) et contient un fichier CSV par ROI. Afin d'obtenir des fichiers de travail aisément exploitable par Knime pour effectuer l'apprentissage ML et la classification, le but recherché est d'obtenir une base de données par zone cérébrale contenant tous les sujets ainsi que leur classe. La première étape consiste donc à regrouper tous les sujets dans un seul fichier par zone cérébrale donnée. Pour ce faire, il s'agit d'itérer à travers chaque dossier afin de regrouper ces informations. Il s'agit ensuite de rajouter une colonne avec l'identifiant du sujet. Enfin, on explore le fichier contenant tous les sujets afin de retrouver le sujet en question ainsi que sa classe. Cette dernière information est rajoutée au fichier de sortie. Ces étapes sont schématisées ci-dessous :

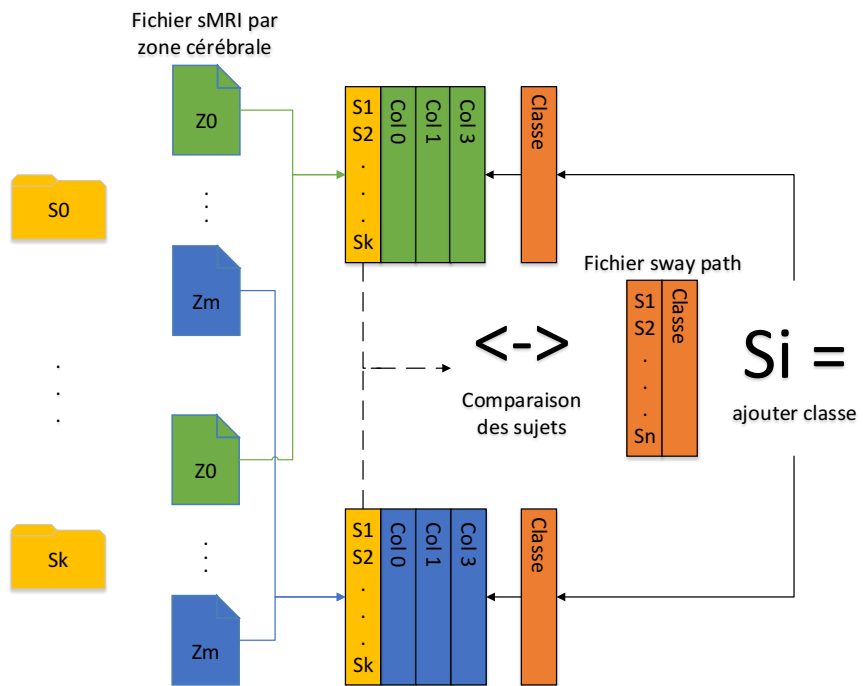


Figure 25 - Préparation et nettoyage des données sMRI en vue du ML

Le flux suivant est la représentation du schéma de principe ci-dessus, transposé dans Knime :

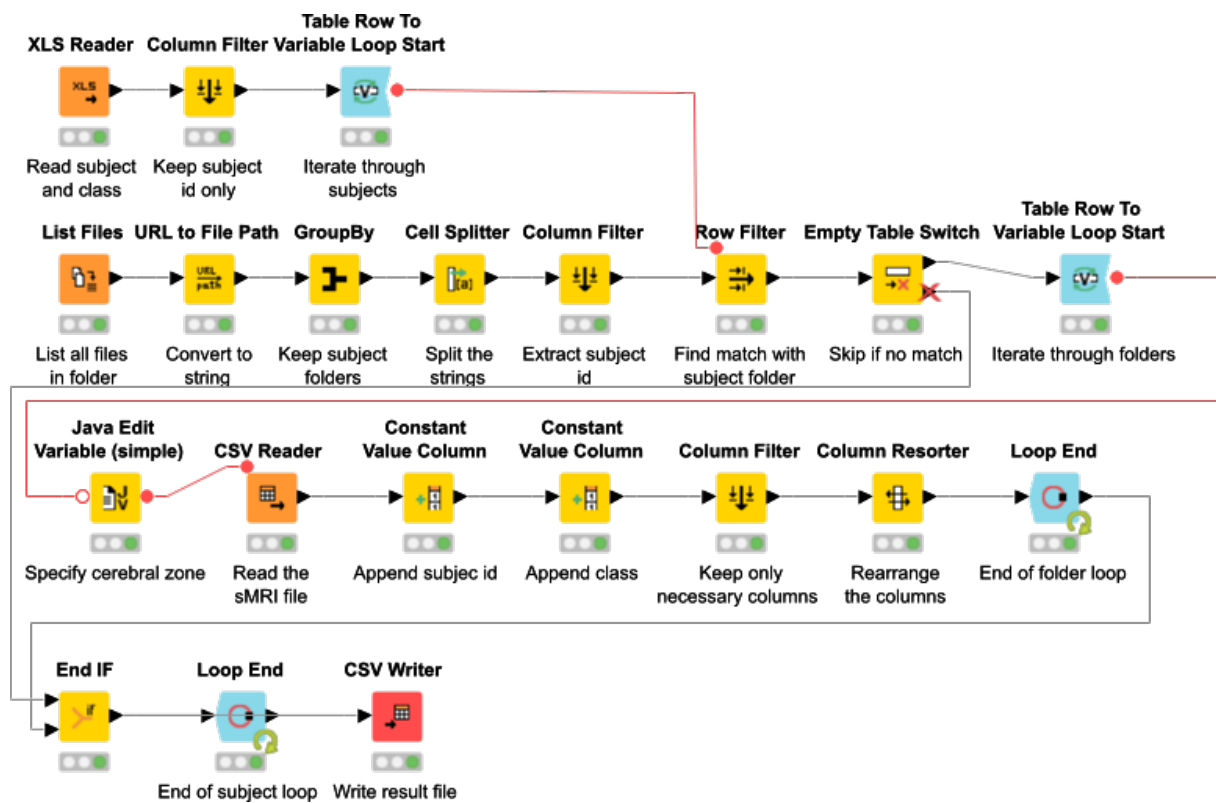


Figure 26 - Flux Knime de préparation des données sMRI

4.3. Itération 1 – Exploration des jeux de données

4.3.1. Description

Dans le cadre de ce projet, l'apprentissage se fera sous forme supervisée étant donné qu'un dataset correctement identifié est à disposition. Le principe de l'apprentissage supervisé repose sur le regroupement en classes des éléments ayant des caractéristiques similaires. Les nouveaux objets sont ensuite associés à la classe la plus proche. Le choix des caractéristiques est crucial, car il doit permettre une bonne discrimination des classes. La première itération a pour but de prendre en mains les jeux de données préalablement préparés dans le but d'un apprentissage et de classification. Pour ce faire, les données utilisées sont celles issues de la phase de nettoyage et préparation. Les buts visés sont :

- obtenir une information sur la pertinence des données (exploitabilité)
- choisir les jeux des données à conserver

Dans cette première itération, ce sont les forêts d'arbres décisionnels qui ont été utilisées. En effet, cette méthode est régulièrement citée dans la littérature (cf. 2.4.2 Modélisation) grâce à son efficacité. Il semble par conséquent judicieux de la maintenir dans cette première étape de prise en main.

4.3.2. Machine Learning

Avec Knime, la difficulté majeure repose sur la préparation adéquate des données. Cette étape est particulièrement chronophage, notamment pour la mise en place des flux, car elle fait appel aux connaissances spécifiques de Knime qu'il faut développer et acquérir sur le moment. Dans le groupe « Scoring », le nœud « Roc Curve » permet d'obtenir l'AUC, le nœud « Scorer » nous donne la précision. A cela, est rajouté un méta-nœud

« Scoring » qui permet d'obtenir un scoring plus avancé en calculant notamment l'écart-type sur les valeurs AUC ainsi que l'intervalle de confiance. Cette démarche est basée sur l'article de (Hanley & McNeil, 1982).

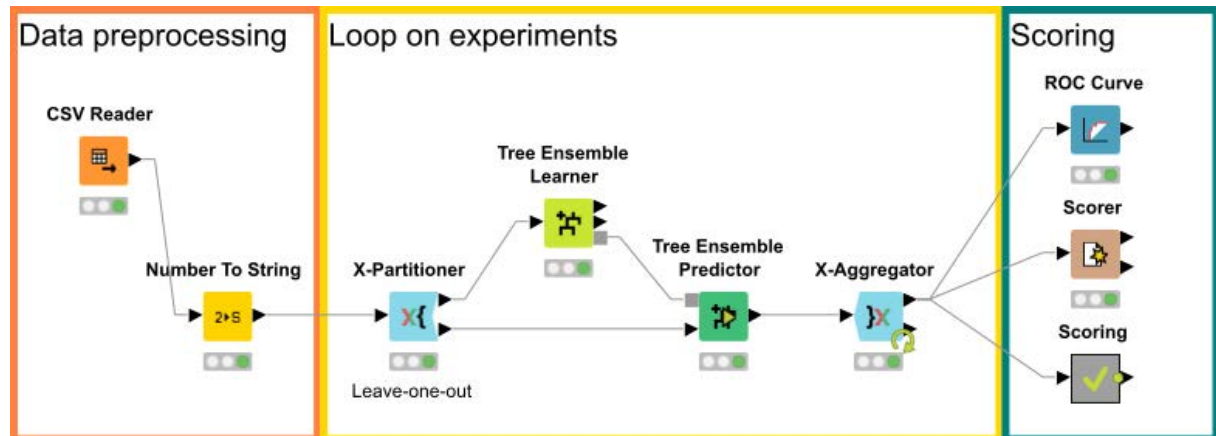


Figure 27 - Flux de Machine Learning, itération de prise en mains

Les étapes sont les suivantes :

1. Lire le fichier CSV correspondant à la condition testée
2. Transformer la colonne contenant la classe en chaîne de caractères
3. Partitionner en utilisant la méthode leave-one-out (cf. 2.4.4 Validation croisée « leave-one-out »)
4. Apprendre avec le modèle spécifique
5. Prédire avec le modèle spécifique
6. Agréger les résultats du leave-one-out
7. Scorer les résultats

4.3.3. Résultats et discussions

Les résultats obtenus par ROI pour les trois jeux de données sont résumés dans les tableaux ci-dessous :

fMRI : condition AOP-Repos

| Zone du cerveau | Précision | AUC | Ecart-type | Intervalle de confiance (95%) |
|-----------------|-----------|------|------------|-------------------------------|
| Entier | 74.2% | 0.45 | 0.11 | 0.22 |
| M1 | 64.5% | 0.51 | 0.12 | 0.23 |
| Cerebellum | 51.6% | 0.38 | 0.11 | 0.21 |
| Putamen | 64.5% | 0.38 | 0.11 | 0.21 |
| SMA | 54.8% | 0.38 | 0.11 | 0.21 |
| S1 | 61.3% | 0.40 | 0.11 | 0.22 |
| PFC | 67.7% | 0.47 | 0.12 | 0.23 |
| Brainstem | 67.7% | 0.39 | 0.11 | 0.22 |
| BG | 67.7% | 0.41 | 0.11 | 0.22 |

Tableau 9 - Résultats itération 1 fMRI AOP-Repos

fMRI : condition AOP-AOS

| Zone du cerveau | Précision | AUC | Ecart-type | Intervalle de confiance (95%) |
|-----------------|-----------|------|------------|-------------------------------|
| Entier | 67.7% | 0.45 | 0.11 | 0.22 |
| M1 | 61.3% | 0.52 | 0.12 | 0.23 |
| Cerebellum | 51.6% | 0.14 | 0.07 | 0.13 |
| Putamen | 67.7% | 0.43 | 0.11 | 0.22 |
| SMA | 61.3% | 0.50 | 0.12 | 0.23 |
| S1 | 54.8% | 0.28 | 0.10 | 0.19 |
| PFC | 64.5% | 0.53 | 0.12 | 0.23 |
| Brainstem | 54.8% | 0.30 | 0.10 | 0.19 |
| BG | 64.5% | 0.41 | 0.11 | 0.22 |

Tableau 10 - Résultats itération 1 fMRI AOP-AOS

sMRI

| Zone du cerveau | Précision | AUC | Ecart-type | Intervalle de confiance (95%) |
|-----------------|-----------|------|------------|-------------------------------|
| Entier | 76.5% | 0.63 | 0.11 | 0.22 |
| M1 | 72.7% | 0.74 | 0.11 | 0.21 |
| SMA | 60.6% | 0.63 | 0.11 | 0.22 |
| Cerebellum | 63.6% | 0.26 | 0.09 | 0.18 |
| S1 | 60.6% | 0.40 | 0.11 | 0.21 |
| PFC | 69.7% | 0.62 | 0.11 | 0.22 |
| Brainstem | 66.7% | 0.54 | 0.12 | 0.23 |
| BG | 66.7% | 0.48 | 0.11 | 0.22 |
| Putamen | 60.6% | 0.18 | 0.08 | 0.15 |

Tableau 11 - Résultats itération 1 sMRI

Dans l'ensemble, les résultats montrent une bonne précision pour les 3 jeux de données. L'AUC est également relativement élevée pour les données sMRI tandis qu'elle est plutôt faible pour les deux jeux de données relatifs au fMRI. La différence de résultats observée entre la précision et l'AUC est expliquée par le fort déséquilibre entre les classes, comme précédemment constaté. En effet, cela peut être imputé au fait que dans les cas où il y a un fort déséquilibre des classes, il est plus facile de toujours prédire la classe dont le plus grand nombre est représenté afin de minimiser les erreurs. Or, nous cherchons à savoir si la méthode est suffisamment robuste pour différencier les deux classes. La précision ne peut donc pas être utilisée comme valeur probatoire. Comme il s'agit d'un problème à 2 classes, il est fort heureusement possible d'utiliser l'AUC qui offre des résultats non biaisés par le déséquilibre entre les classes. Dorénavant, nous nous intéresserons donc essentiellement à l'AUC plutôt qu'à la précision.

Concernant les données fMRI, dans le meilleur des cas, l'AUC affiche une valeur juste au-dessus de 0.5, ce qui veut dire que le modèle ne performe pas mieux qu'un modèle naïf qui classerait de façon aléatoire. Dans le pire des cas, l'AUC est proche de 0.1, montrant de piètres résultats. Etant donné ces observations, il n'est pas encore possible de pouvoir se prononcer sur les zones du cerveau associées à l'équilibre pour ce qui est des deux jeux de données fMRI. Il faudra donc persévérer en procédant à d'autres itérations.

Pour ce qui est des données sMRI, l'AUC présente de très bons résultats malgré une classification ne s'opérant qu'avec 3 attributs (matière blanche, matière grise, LCS). A l'instar des données fMRI qui s'organisent sur plusieurs milliers d'attributs. Ainsi, pour ce qui est des données sMRI, nous retenons uniquement M1. De plus, il

n'est pas nécessaire d'effectuer des itérations supplémentaires pour sélectionner lesquels des 3 attributs des données sMRI sont à garder car la forêt d'arbres décisionnels le fait déjà intrinsèquement.

| Zone cerveau | AUC | Ecart-type | Intervalle de confiance (95%) |
|--------------|------|------------|-------------------------------|
| M1 | 0.74 | 0.11 | 0.21 |

Tableau 12 – Région cérébrale retenue avec les données sMRI

La région cérébrale donnant les meilleurs résultats sMRI est le cortex moteur primaire (M1), dont une des fonctions principales est de contrôler les mouvements volontaires des membres. Ainsi, ce résultat est représentatif et montre que les données comportementales liées à l'équilibre chez les personnes âgées ont une influence conséquente sur les données cérébrales représentant ces fonctions.

4.4. Itération 2 – Réduction du bruit dans les données fMRI

4.4.1. Description

Les résultats fMRI de la première itération souffrent d'une AUC pas suffisamment élevée pour pouvoir tirer des conclusions. L'hypothèse émise est que les données fMRI contiennent du bruit concernant les voxels communs aux deux classes (redondance d'informations). Afin que le classificateur puisse performer de façon adéquate, il est important de lui présenter des attributs les plus distincts possible entre les classes. Pour ce faire, l'idée est de calculer la moyenne des attributs par classe et de ne conserver que ceux qui ont au moins un écart-type de différence. Entre les deux écarts-types possibles, le choix a été arbitrairement retenu de prendre celui de la classe 1 (bon équilibre). Cette étape de filtrage peut-être modélisée à l'aide du logigramme suivant :

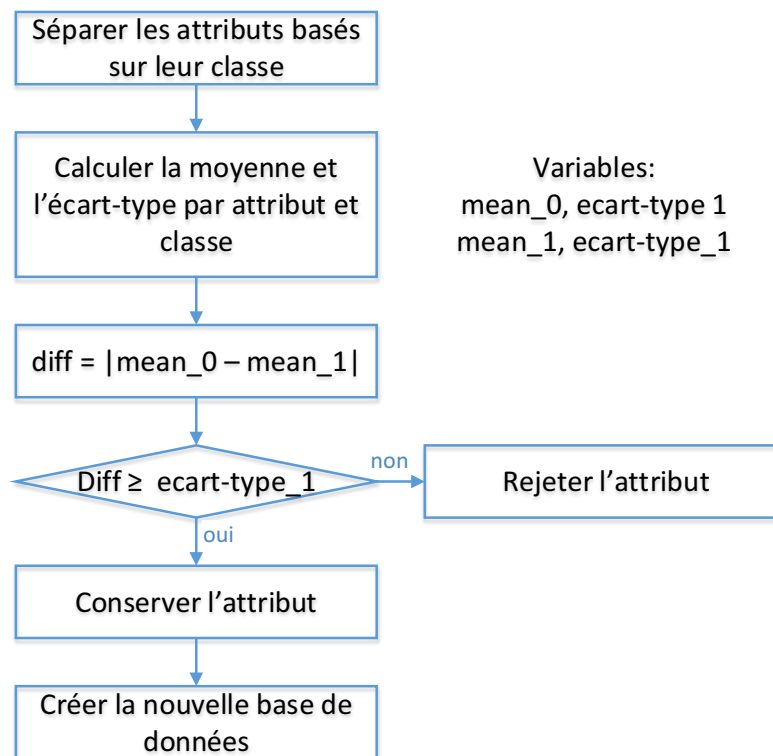


Figure 28 - Nettoyage basé sur la moyenne et l'écart-type des attributs

4.4.2. Flux de préparation

Les étapes de préparations décrites ci-dessus se modélisent dans Knime de la façon suivante :

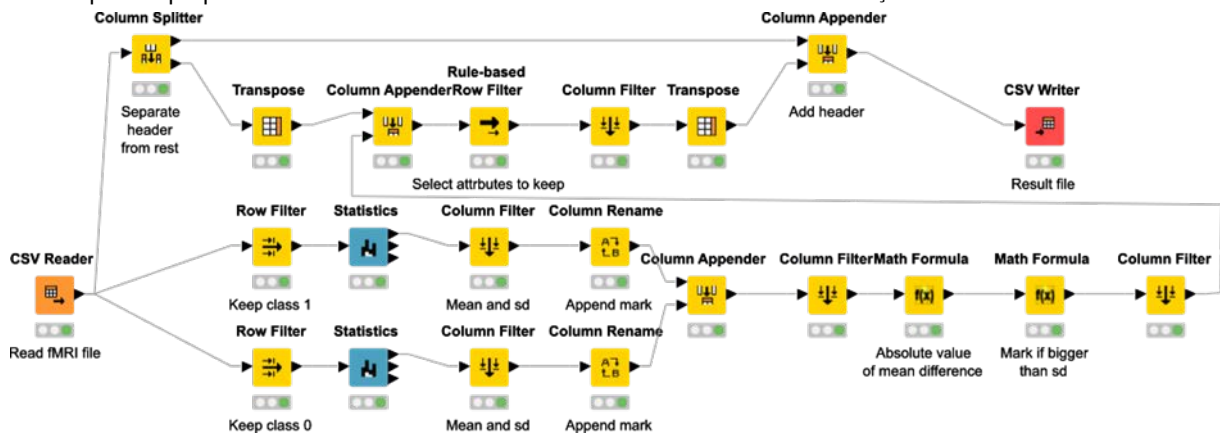


Figure 29 - Flux de préparation pour filtrage du bruit des données fMRI

Astuces et défis

Malgré une configuration machine récente, il a été compliqué de mener à bien certaines itérations qui furent gourmandes en ressources. Aussi, nous avons dû utiliser une machine tierce avec des spécifications techniques très avancées. Les nœuds les plus chronophages sont les transposées et les traitements statistiques (entre une et deux heures pour chaque nœud, demandant au total environ 5 heures pour le flux complet par ROI et une surveillance permanente). A cela s'ajoute que certaines relations entre les nœuds n'est parfois pas optimale, en effet, nous avons dû solliciter la communauté Knime afin de résoudre un problème de transition¹⁶ (voir également annexe 10.3 Aide postée sur le forum Knime). Malgré une réponse rapide de nos interlocuteurs, il est apparu que cette erreur était connue, mais pas encore corrigée dans la version actuelle de Knime. Il apparaît dommage qu'un logiciel se profilant en tant que Machine Learning et Data Mining puisse souffrir de certains défauts, surtout lors de l'analyse d'un petit lot de données.

4.4.3. Machine Learning

L'avantage de Knime repose dans le fait qu'une fois les données bien préparées, les flux d'apprentissages sont rapidement mis en place. Ces derniers étant similaires à l'itération 1, il n'est pas nécessaire de les décrire à nouveau.

¹⁶ Lien vers la question posée sur le forum : <https://tech.knime.org/forum/knime-general/cannot-open-statistics-configuration-view-with-big-csv-file>

4.4.4. Résultats et discussions

fMRI : condition AOP-Repos

| Zone du cerveau | Précision | AUC | Ecart-type | Intervalle de confiance (95%) | Nb attributs itér. 1 | Nb attributs itér. 2 | Pourcentage gardé |
|-----------------|-----------|------|------------|-------------------------------|----------------------|----------------------|-------------------|
| Entier | 80.6% | 0.69 | 0.11 | 0.22 | 139629 | 8708 | 6.2% |
| M1 | 64.5% | 0.60 | 0.12 | 0.23 | 2867 | 61 | 2.1% |
| Cerebellum | 61.3% | 0.50 | 0.12 | 0.23 | 6001 | 2 | < 0.1% |
| Putamen | 64.5% | 0.60 | 0.12 | 0.23 | 565 | 61 | 10.8% |
| SMA | 71.0% | 0.68 | 0.11 | 0.22 | 6731 | 76 | 1.1% |
| S1 | 61.3% | 0.53 | 0.12 | 0.23 | 6731 | 94 | 1.4% |
| PFC | 77.4% | 0.76 | 0.10 | 0.20 | 5124 | 1561 | 30.5% |
| Brainstem | 61.3% | 0.51 | 0.12 | 0.23 | 21434 | 15 | <0.1% |
| BG | 74.2% | 0.62 | 0.12 | 0.23 | 544 | 137 | 25.2% |

Tableau 13 - Résultats itération 2 fMRI AOP-Repos

fMRI : condition AOP-AOS

| Zone du cerveau | Précision | AUC | Ecart-type | Intervalle de confiance (95%) | Nb attributs itér. 1 | Nb attributs itér. 2 | Pourcentage gardé |
|-----------------|-----------|------|------------|-------------------------------|----------------------|----------------------|-------------------|
| Entier | 80.0% | 0.78 | 0.10 | 0.20 | 139629 | 4366 | 3.1% |
| M1 | 74.2% | 0.62 | 0.12 | 0.23 | 2867 | 74 | 2.6% |
| Cerebellum | - | - | - | - | 6001 | 0 | 0.0% |
| Putamen | 74.2% | 0.5 | 0.12 | 0.23 | 565 | 2 | 0.4% |
| SMA | 67.7% | 0.67 | 0.11 | 0.22 | 6731 | 131 | 1.9% |
| S1 | 74.2% | 0.78 | 0.10 | 0.20 | 5124 | 38 | 0.7% |
| PFC | 67.7% | 0.63 | 0.12 | 0.23 | 21434 | 1226 | 5.7% |
| Brainstem | - | - | - | - | 544 | 0 | 0.0% |
| BG | 74.2% | 0.59 | 0.12 | 0.23 | 1022 | 19 | 1.9% |

Tableau 14 - Résultats itération 2 fMRI AOP-AOS

Il est intéressant de constater que le travail de nettoyage des données entrepris dans cette itération trouve sa justification. Globalement, la précision augmente pour les deux conditions testées et, de façon plus importante également l'AUC. Les valeurs de l'AUC sont cette fois bien supérieures à 0.5 pour la majorité des zones cérébrales traitées. De plus, nous constatons que le nettoyage effectué ne garde plus qu'une quantité très limitée des informations de départ (10.8% dans le meilleur des cas), confirmant ainsi l'hypothèse de la redondance des données liées aux voxels entre les classes.

Concernant la condition AOP – Repos, la zone ayant une AUC de plus de 0.75 est les PFC :

| Zone cerveau | AUC | AUC | Ecart-type |
|--------------|------|------|------------|
| PFC | 0.76 | 0.10 | 0.20 |

Tableau 15 - Résultat retenu itération 2 fMRI AOP-Repos

Pour ce qui est de la condition AOP – AOS, après nettoyage, le cerbellum ne contient pas de données suffisamment distinctes entre les 2 classes et en conséquence doit être écarté de la liste. De plus, le putamen présentant une AUC de seulement 0.5 doit être également écarté, les deux zones les plus représentatives de l'équilibre sont donc :

| Zone cerveau | AUC | AUC | Ecart-type |
|--------------|------|------|------------|
| Entier | 0.78 | 0.10 | 0.20 |
| S1 | 0.78 | 0.10 | 0.20 |

Tableau 16 - Résultats retenus itération 2 fMRI AOP-AOS

Pour la condition AOP-Repos, seule l'AUC de la région PFC est suffisamment élevée pour être retenue. Le manque de régions représentées dans ce cas peut être lié aux conditions expérimentales. En effet, pour la condition de repos, les sujets avaient pour indication de regarder une croix sans se représenter quoi que ce soit. Il est difficile de contrôler cet état et de s'assurer que tous les sujets aient vraiment exécuté l'instruction de façon similaire. Toutefois, le PFC est une zone engagée dans le contrôle cognitif et dans les aptitudes à orchestrer les pensées, il intervient notamment dans les cas où les comportements doivent être guidés par des états internes ou des intentions. Il est donc intéressant de constater que la façon dont les individus peuvent s'imaginer contrer une tâche d'équilibre dynamique (condition AOP) est liée à leur capacité d'équilibre physique. Cela permet d'envisager des tâches où il n'est même plus nécessaire de demander à l'individu d'effectuer physiquement l'activité.

En ce qui concerne la condition AOP-AOS, garder toutes les régions du cerveau semble être aussi efficace que de ne garder que la région S1. Etant donné que le traitement des données est lourd en ressources computationnelles, il est intéressant de pouvoir isoler uniquement S1 afin de gagner du temps. S1 est le cortex somatosensoriel primaire et s'occupe non seulement de recevoir les informations sensorielles mais est également impliqué dans la mémorisation des tâches tactiles ou visuelles. Etant donné que regarder une vidéo et s'imaginer contrer une perturbation fait justement intervenir ce genre de stimulus, il est intéressant de constater que tout comme pour PFC, S1 permet d'obtenir des informations comportementales sans que le sujet n'effectue de réels mouvements.

4.5. Itération 3 – Autres classificateurs

4.5.1. Description

L'objectif de cette itération est de comparer les classificateurs entre eux. En effet, lors des itérations précédentes, uniquement le classificateur de forêts d'arbres décisionnels a été utilisé. Pour ce faire, les zones cérébrales retenues dans les itérations précédentes sont utilisées pour tester la performance des classificateurs suivants :

| Classificateurs | Paramètres |
|------------------------------|---|
| Arbres de décisions | Mesure de qualité : Gini index Méthode de pruning : aucune Nombre d'enregistrements minimaux par nœud : 2 |
| Forêts d'arbres décisionnels | Critère de séparation : Information Gain Ratio Nombre de modèles : 100 |
| K plus proches voisins | Nombre de voisins considérés : 50 Pesée des voisins par distance : oui |
| Réseaux de neurones | Nombre maximal d'itérations : 100 Nombre de couches cachées : 1 Nombre de neurones cachés par couche : 10 Normalisation : Score Z (Gaussien) |

Tableau 17 - Classificateurs retenus et leurs paramètres

4.5.2. Flux de préparation

Dans cette étape, aucun flux de préparation supplémentaire n'est nécessaire. Il s'agit uniquement de tester les différents algorithmes de ML.

4.5.3. Machine Learning

Dans l'ensemble, les flux de Machine Learning sont similaires aux itérations précédentes. Les principales différences résident dans le fait qu'un nœud supplémentaire a été introduit afin de regrouper les scores des différents classificateurs et pouvoir les sauvegarder dans un fichier Excel.

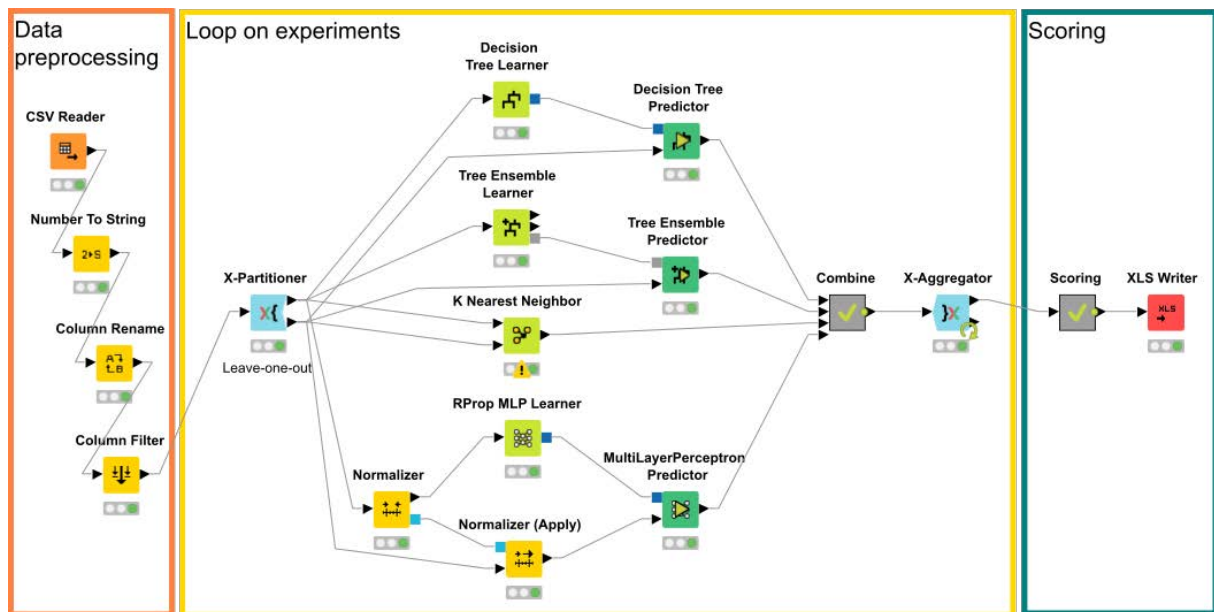


Figure 30 - Flux de Machine Learning avec différents classificateurs

4.5.4. Résultats et discussions

fMRI : condition AOP-Repos

| Zone cerveau | Classificateur | AUC | Ecart-type | Intervalle de confiance (95%) |
|--------------|------------------------------|------|------------|-------------------------------|
| PFC | Arbres de décisions | 0.86 | 0.08 | 0.17 |
| | Forêts d'arbres décisionnels | 0.77 | 0.10 | 0.20 |
| | K plus proches voisins | 0.54 | 0.12 | 0.23 |
| | Réseaux de neurones | 0.69 | 0.11 | 0.22 |

Tableau 18 - Résultats itération 3 fMRI AOP-Repos

fMRI : condition AOP-AOS

| Zone cerveau | Classificateur | AUC | Ecart-type | Intervalle de confiance (95%) |
|--------------|------------------------------|------|------------|-------------------------------|
| Entier | Arbres de décisions | 0.67 | 0.11 | 0.22 |
| | Forêts d'arbres décisionnels | 0.78 | 0.10 | 0.20 |
| | K plus proches voisins | 0.58 | 0.12 | 0.23 |
| | Réseaux de neurones | 0.81 | 0.10 | 0.19 |
| S1 | Arbres de décisions | 0.63 | 0.12 | 0.23 |
| | Forêts d'arbres décisionnels | 0.79 | 0.10 | 0.20 |
| | K plus proches voisins | 0.66 | 0.11 | 0.22 |
| | Réseaux de neurones | 0.90 | 0.07 | 0.14 |

Tableau 19 - Résultats itération 3 fMRI AOP-AOS

sMRI

| Zone cerveau | Classificateur | AUC | Ecart-type | Intervalle de confiance (95%) |
|--------------|------------------------------|------|------------|-------------------------------|
| M1 | Arbres de décision | 0.64 | 0.11 | 0.22 |
| | Forêts d'arbres décisionnels | 0.74 | 0.11 | 0.21 |
| | K plus proches voisins | 0.50 | 0.11 | 0.22 |
| | Réseaux de neurones | 0.41 | 0.11 | 0.21 |

Tableau 20 - Résultats itération 3 sMRI

La prise en compte des différents classificateurs a permis d'améliorer les résultats obtenus jusqu'alors et permet de renforcer les interprétations des résultats présentés lors de l'itération précédente. Pour la condition fMRI AOP-Repos, l'arbre de décisions performe mieux que la forêt d'arbres décisionnels avec une AUC de 0.86. Pour les deux conditions fMRI AOP-AOS, ce sont les réseaux de neurones qui offrent les meilleurs résultats comme l'indique les valeurs AUC de 0.81 pour le cerveau entier et 0.90 pour S1. En ce qui concerne les données sMRI, la forêt d'arbres décisionnels garde son meilleur score d'AUC de 0.74. En outre, il est plaisant de constater que pour traiter les données provenant du cerveau, c'est justement les réseaux de neurones artificiels qui permettent d'obtenir les meilleurs résultats.

4.6. Itération 4 – combinaison fMRI avec sMRI

4.6.1. Description

Dans les itérations précédentes, les méthodes fMRI et sMRI ont été traitées séparément conformément aux usages du domaine de la neurologie. Cette itération a pour but de s'extraire des modèles traditionnels et de vérifier si la combinaison de ces deux méthodes permet d'améliorer les prédictions. Pour ce faire, seules les ROI retenues précédemment sont prises en considération.

4.6.2. Flux de préparation

Afin de parvenir à ces fins, il est nécessaire de préparer une nouvelle base de données contenant les attributs nécessaires. La mise en œuvre consiste à lire les fichiers fMRI et itérer à travers ceux du sMRI afin de trouver les sujets qui sont communs. Si tel est le cas, alors les valeurs des 3 volumes sMRI sont ajoutées au fichier fMRI et le résultat est sauvegardé dans un nouveau fichier CSV.

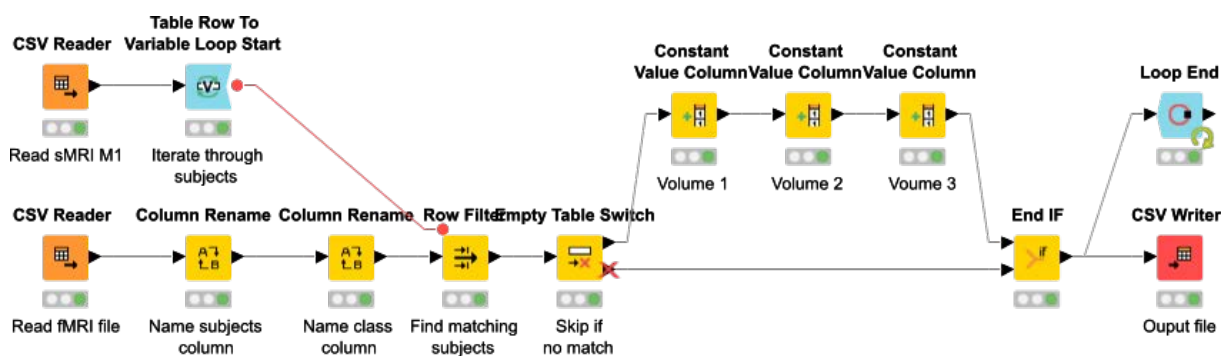


Figure 31 - Flux de préparation pour base de données contenant fMRI et sMRI

4.6.3. Machine Learning

Les flux de ML restent identiques à ceux de l'itération précédente.

4.6.4. Résultats et discussions

fMRI : condition AOP-Repos + sMRI (M1)

| Zone cerveau | Classificateur | AUC | Ecart-type | Intervalle de confiance (95%) |
|--------------|------------------------------|------|------------|-------------------------------|
| PFC + M1 | Arbres de décisions | 0.90 | 0.07 | 0.14 |
| | Forêts d'arbres décisionnels | 0.79 | 0.10 | 0.19 |
| | K plus proches voisins | 0.54 | 0.12 | 0.23 |
| | Réseaux de neurones | 0.71 | 0.11 | 0.21 |

Tableau 21 - Résultats itération 4 fMRI AOP-Repos et sMRI

fMRI : condition AOP-AOS + sMRI (M1)

| Zone cerveau | Classificateur | AUC | Ecart-type | Intervalle de confiance (95%) |
|--------------|------------------------------|------|------------|-------------------------------|
| Entier + M1 | Arbres de décisions | 0.67 | 0.11 | 0.22 |
| | Forêts d'arbres décisionnels | 0.74 | 0.11 | 0.21 |
| | K plus proches voisins | 0.58 | 0.12 | 0.23 |
| | Réseaux de neurones | 0.63 | 0.12 | 0.23 |
| S1 + M1 | Arbres de décisions | 0.63 | 0.12 | 0.23 |
| | Forêts d'arbres décisionnels | 0.82 | 0.09 | 0.18 |
| | K plus proches voisins | 0.66 | 0.11 | 0.22 |
| | Réseaux de neurones | 0.69 | 0.11 | 0.22 |

Tableau 22 - Résultats itération 4 fMRI AOP-AOS et sMRI

Pour la condition fMRI AOP-Repos, l'ajout des informations sMRI de la région M1 donne un excellent résultat avec une AUC de 0.9 avec le classificateur des arbres de décisions, contre 0.86 lors de l'itération précédente. Pour la condition fMRI AOP-AOS, l'ajout des données sMRI ne permet pas d'améliorer la prédiction. Cette constatation est valable pour les deux régions traitées, à savoir le cerveau entier et le S1. Le meilleur AUC étant respectivement de 0.74 contre 0.81 lors de la précédente itération et 0.82 contre 0.9.

La combinaison des données fMRI et sMRI est une combinaison peu utilisée par les neurologues qui préfèrent séparer ces deux types d'analyse. Toutefois, la condition fMRI AOP-Repos combinée au sMRI M1 permet d'obtenir le meilleur résultat jusqu'à présent et ce, malgré le fait que la condition de repos soit difficilement contrôlable lors des expérimentations.

4.7. Itération 5 – Détection des éléments mal classés

4.7.1. Description

La dernière itération ainsi que la précédente ont permis d'obtenir de bons résultats. La présente itération vise à reprendre les deux meilleurs résultats afin de voir exactement quels sont les éléments qui ont été mal classifiés et tenter de définir une stratégie pour les améliorer. Pour rappel, les 2 meilleurs résultats sont les suivants :

| Cas | Conditions | Zone cerveau | Classificateur | AUC | Précision |
|-----|--------------------------|--------------|---------------------|------|-----------|
| #1 | fMRI AOP-AOS | S1 | Réseau de neurones | 0.90 | 83.9% |
| #2 | fMRI AOP-Repos + sMRI M1 | PFC + M1 | Arbres de décisions | 0.90 | 83.9% |

Tableau 23 - Rappel des 2 meilleurs résultats

4.7.2. Flux de préparation

Dans cette phase, il n'y a pas de flux de préparation étant donné qu'il s'agit avant tout d'analyser les résultats obtenus.

4.7.3. Machine Learning

Il n'y a pas de Machine Learning non plus.

4.7.4. Résultats et discussions

Afin de pouvoir interpréter les résultats, les sujets mal classés sont présentés. A cela, l'information sur le nombre de fois que le participant a posé le pied gauche (suite à une perte d'équilibre) durant l'expérience est précisée. En outre, la probabilité de prédiction des classificateurs est reprise.

Cas #1 : fMRI AOP-AOS S1, réseau de neurones

| Sujet (ID) | Sway path mm | Nb de fois posé le pied | P(0) | P(1) | Classe | Prédiction |
|------------|--------------|-------------------------|---------|-------|--------|------------|
| S52 | 76.09 | 0 | 1.0 | 0.0 | 1 | 0 |
| S14 | 151.43 | 1 | 2.5E-10 | 0.001 | 0 | 1 |
| S18 | 60.32 | 0 | 1.0 | 0.0 | 1 | 0 |
| S30 | 180.41 | 1 | 0.0 | 1.0 | 0 | 1 |
| S35 | 117.77 | 0 | 1.0 | 0.0 | 1 | 0 |

Tableau 24 - Instances mal classées du meilleur résultat n° 1

Cas #2 : fMRI AOP-AOS PFC + sMRI M1, arbres de décisions

| Sujet (ID) | Sway path mm | Nb de fois posé le pied | P(0) | P(1) | Classe | Prédiction |
|------------|--------------|-------------------------|-------|-------|--------|------------|
| S14 | 151.43 | 1 | 0.0 | 1.0 | 0 | 1 |
| S18 | 60.32 | 0 | 1.0 | 0.0 | 1 | 0 |
| S21 | 270.30 | 0 | 0.043 | 0.957 | 0 | 1 |
| S25 | 162.34 | 0 | 0.043 | 0.957 | 0 | 1 |
| S30 | 180.41 | 1 | 0.043 | 0.957 | 0 | 1 |

Tableau 25 - Instances mal classées du meilleur résultat n° 2

On constate dans les deux cas que cinq instances ont été mal classifiées, donnant une précision de 83.9%. Il est intéressant de remarquer que parmi ces cinq instances, on retrouve trois mêmes sujets (S14, S18 et S30) alors que dans les deux cas traités ni les régions cérébrales, ni le classificateur utilisé ne sont identiques. Pour ces trois sujets, les deux algorithmes sont persistants dans leur prédiction et les classifient comme étant respectivement bon, mauvais et bon. Pour les sujets 18 et 30, la probabilité est très forte (P(1) entre 0.957 et 1.0) dans les deux cas, tandis que pour le sujet 14, elle est extrêmement faiblement prédite dans le cas 1 ($P(0) = 2.5E-10$ et $P(1) = 0.001$) et maximale dans le cas 2. De plus, le sujet 14 a un sway path très proche du seuil de séparation entre les classes fixé à 150 mm et l'hypothèse pourrait être émise que l'erreur de classement est liée au seuil placé sans tolérance. Toutefois, tout comme le sujet 30, ils ont dû s'aider du deuxième pied durant la tâche d'équilibre, ce qui renforce l'hypothèse de candidats ayant un mauvais équilibre malgré la prédiction contraire des deux classificateurs. Le sujet 21 a un sway path de 270.30 mm qui est le maximum enregistré (cf. Figure 16 - Statistiques sur le sway path et Figure 17 - Boxplot sur les données relatives à l'équilibre). Il pourrait donc s'agir d'une erreur de mesures et peut être considéré comme un outlier à sortir du jeu de données. Les sujets 52 et 35 ont clairement un sway path faibles et n'ont pas posé le deuxième pied au sol durant les exercices, tout concorde à les classer comme étant des sujets à bon équilibre malgré la probabilité maximale vers un mauvais équilibre du classificateur. Enfin, le sujet 25 a un sway path proche du seuil de séparation et peut être considéré comme étant dans la zone d'incertitude. Etant donné qu'il n'a pas posé le pied par terre, il serait envisageable de suivre la prédiction du classificateur et le considérer comme faisant partie du groupe ayant un bon équilibre. En somme, cette itération montre les limites du système et que parmi les 7 sujets mal classés, seul un (le sujet 25) pourrait être reclassé de mauvais équilibre vers bon équilibre. Toutefois, le faible gain que cette reclassification pourrait engendrer ne justifie pas un nouveau passage de ML.

4.8. Itération 6 – Amélioration des résultats sMRI

4.8.1. Description

Les itérations précédentes ont permis d'obtenir de bons résultats pour les données fMRI que ce soit pour la condition AOP-Rest ou AOP-AOS avec des AUC de 0.9. Toutefois, les données sMRI n'ont pas pu être améliorées et gardent leur score de 0.74 pour la région M1. La présente itération a pour but de reprendre les données sMRI de la région M1 et d'itérer à travers les paramètres du classificateur de la forêt d'arbres décisionnels : nombre de modèles du classificateur et critère de séparation. Jusqu'à présent, la valeur de 100 modèles a été retenue de façon arbitraire et le critère était basé sur le ratio du gain d'information. Il n'est pas nécessaire de diminuer le nombre de modèles car une fois le nombre maximal atteint, les modèles supplémentaires ne sont tout simplement pas utilisés.

Parmi les critères de séparation, Knime permet les choix suivants :

- **Index Gini** : mesure de la fréquence à laquelle un élément choisi aléatoirement du jeu de données serait labélisé de façon incorrecte si son étiquette était choisie aléatoirement parmi la distribution des étiquettes. Une grande valeur de Gini indique une grande différence dans deux nœuds enfants (Lemon, Roy, Clark, Friedmann, & Rakowski, 2003).
- **Gain d'information** : cette méthode est utilisée par l'algorithme C4.5 de générations d'arbres et se base sur des calculs d'entropie, tel que défini par (Quinlan, 1993).
- **Ratio de gain d'information** : normalisation du gain standard d'information par l'entropie de séparation afin de surmonter certaines préférences inéquitables pour les séparations nominales avec beaucoup de nœuds enfants (Knime GmbH, 2016).

4.8.2. Flux de préparation

Dans cette phase, il n'y a pas de flux de préparation étant donné qu'il s'agit de reprendre la base de données créée lors de la phase 4.2.3 Nettoyage et préparation des données SMRI.

4.8.3. Machine Learning

Les flux de Machine Learning sont identiques à ceux utilisés lors de l'itération 1.

4.8.4. Résultats et discussions

Les résultats des itérations sur les critères de séparation et le nombre de modèles sont présentés ci-dessous. Le nombre de modèles ont été affectés selon la séquence suivante : 100, 300, 500, 750 et 1000.

| Critère de séparation | Nombre de modèles | AUC | Ecart-type | Intervalle de confiance (95%) |
|-----------------------------|-------------------|------|------------|-------------------------------|
| Ratio de gain d'information | 100 | 0.74 | 0.11 | 0.21 |
| | 300 | 0.76 | 0.10 | 0.20 |
| | 500 | 0.78 | 0.10 | 0.20 |
| | 750 | 0.77 | 0.10 | 0.20 |
| | 1000 | 0.77 | 0.10 | 0.20 |
| Index Gini | 100 | 0.74 | 0.11 | 0.21 |
| | 300 | 0.76 | 0.10 | 0.20 |
| | 500 | 0.76 | 0.10 | 0.20 |
| | 750 | 0.76 | 0.10 | 0.20 |
| | 1000 | 0.76 | 0.10 | 0.20 |
| Gain d'information | 100 | 0.74 | 0.11 | 0.21 |
| | 300 | 0.76 | 0.10 | 0.20 |
| | 500 | 0.78 | 0.10 | 0.20 |
| | 750 | 0.77 | 0.10 | 0.20 |
| | 1000 | 0.77 | 0.1 | 0.20 |

Tableau 26 - Itérations sur les paramètres des forêts d'arbres décisionnels pour les données SMRI

Cette itération a permis d'augmenter l'AUC de 0.74 à 0.78. L'augmentation n'est pas remarquablement élevée mais elle permet de gagner tout de même 4% en valeur absolue et 5.4% en valeur relative. L'écart-type et l'intervalle de confiance restent sensiblement identiques, respectivement de 0.10 et 0.20. Les critères de séparation de ratio de gain d'information et de gain d'information donnent exactement les mêmes résultats. Ils ont permis d'obtenir les meilleurs scores AUC. L'index Gini progresse moins rapidement et donne des résultats légèrement inférieurs. On constate également que 500 modèles permettent d'obtenir les meilleurs scores et qu'il n'est pas nécessaire d'augmenter ce nombre car au-delà, on constate une stagnation des résultats qui montrent que les séparations supplémentaires ne sont tout simplement pas utilisées.

5. Synthèse et conclusion

5.1. Synthèse des résultats obtenus

Six itérations ont pu être menées. Chacune a amené sa contribution à une meilleure compréhension des données et à l'amélioration des résultats, conformément aux recommandations de la méthodologie CRISP-DM.

La phase de préparation avait pour but de nettoyer et mettre en forme les données afin d'obtenir une base exploitable pour le ML. Elle a notamment permis de définir la population en deux classes : « bon équilibre » et « mauvais équilibre » basé sur le seuil de 150 mm du SP. La première itération a permis de découvrir les jeux de données et d'effectuer le ML à l'aide de l'algorithme de la forêt d'arbres décisionnels sur les toutes les ROI cérébrales à disposition. Il en est ressorti que les AUC n'étaient pas suffisamment élevées (> 0.7) pour les données fonctionnelles. A contrario, les données structurelles ont permis d'obtenir une AUC de 0.74 (SD = 0.12) pour la région M1.

La deuxième itération se concentre uniquement sur les données fonctionnelles et un nettoyage du bruit a été entrepris en se basant sur la moyenne et l'écart-type des attributs. Le but étant de ne conserver que ceux dont l'écart est suffisamment distant entre les 2 classes. Ce travail a permis d'obtenir une AUC de 0.76 (SD = 0.1) pour la région PFC avec la condition AOP-Repos. La condition AOP-AOS a permis de sortir deux AUC aux valeurs identiques de 0.78 (SD = 0.1) pour la région S1 et le cerveau en entier. Cette itération a permis de mettre en lumière que seule une faible partie des voxels contient de l'information utile à notre objectif, seulement 1 à 6% des voxels ont été conservés, 10% dans le meilleur des cas. Jusqu'alors, la forêt d'arbres décisionnels était le classificateur qui a permis d'obtenir ces résultats.

La troisième itération vise à explorer d'autres classificateurs dont la sélection retenue est : les arbres de décisions, k plus proches voisins et les réseaux de neurones, en plus de la forêt d'arbres décisionnels. Cette itération a permis d'améliorer les résultats des données fonctionnelles tandis que pour les structurelles la forêt d'arbres décisionnels continue de donner le meilleur résultat. Au niveau des données fonctionnelles, les arbres de décisions ont permis d'obtenir une AUC de 0.86 (SD = 0.08) pour la région PFC avec la condition AOP-Repos. Pour la condition AOP-AOS, ce sont les réseaux de neurones qui offrent de meilleurs résultats. Ainsi ils permettent d'obtenir une AUC de 0.81 (SD = 0.1) pour le cerveau entier et une AUC de 0.90 (SD = 0.07) pour la région S1. Cette étape a non seulement amélioré l'AUC moyen des ROI et a également permis de réduire l'écart-type pour deux des trois valeurs de l'AUC, ce qui augmente la confiance sur la prédiction. Jusqu'à cette itération, le soin a été pris de bien séparer les données cérébrales fonctionnelles des structurelles.

La quatrième itération met un terme à cette séparation et combine les données structurelles de la région M1 ayant donné le meilleur score avec celles des fonctionnelles. Cette combinaison a été testée avec l'ensemble des classificateurs de l'itération précédente. Les arbres de décisions ont permis d'améliorer les résultats de la région PFC combinée aux données structurelles de la région M1 avec une AUC de 0.9 (SD = 0.07). A nouveau l'écart-type de 0.7 nous donne une bonne confiance sur le résultat obtenu. Les deux dernières itérations ont respectivement pour objectif de tenter d'améliorer les résultats des données fonctionnelles et structurelles.

Ainsi, la cinquième itération est une tentative pour expliquer les mauvaises classifications des données fonctionnelles (S1 et PFC combinée à M1). Chacun des cas possède cinq éléments mal classés. Une analyse attentive n'a toutefois pas permis de dégager une structure permettant d'établir une stratégie pour poursuivre la réflexion.

Enfin, la dernière itération vise à améliorer la région M1 des données structurelles. Pour ce faire, les paramètres de la forêt d'arbres décisionnels ont été revus afin de les optimiser. Cela a permis d'augmenter l'AUC et d'obtenir une valeur de 0.78 (SD = 0.10). Ce résultat est obtenu avec 500 modèles et est identique, soit avec le critère de séparation « Ratio de gain d'information » soit avec le « Gain d'information ».

Au terme de ces itérations, les meilleurs résultats obtenus sont résumés ci-dessous :

fMRI : condition AOP-Repos

| Zone cerveau | Classificateur | AUC | Ecart-type | Intervalle de confiance (95%) |
|--------------|---------------------|------|------------|-------------------------------|
| PFC | Arbres de décisions | 0.86 | 0.08 | 0.17 |

fMRI : condition AOP-AOS

| Zone cerveau | Classificateur | AUC | Ecart-type | Intervalle de confiance (95%) |
|--------------|---------------------|------|------------|-------------------------------|
| Entier | Réseaux de neurones | 0.81 | 0.10 | 0.19 |
| S1 | Réseaux de neurones | 0.90 | 0.07 | 0.14 |

sMRI

| Zone cerveau | Classificateur | AUC | Ecart-type | Intervalle de confiance (95%) |
|--------------|------------------------------|------|------------|-------------------------------|
| M1 | Forêts d'arbres décisionnels | 0.78 | 0.10 | 0.20 |

Combinaison fMRI (AOP-Repos) et sMRI

| Zone cerveau | Classificateur | AUC | Ecart-type | Intervalle de confiance (95%) |
|--------------|---------------------|------|------------|-------------------------------|
| PFC + M1 | Arbres de décisions | 0.90 | 0.07 | 0.14 |

Au niveau neurologique, parmi les différentes régions cérébrales traitées, celles où les meilleurs résultats sont obtenus font intervenir le PFC, le S1, le M1 ainsi que le cerveau dans son entier. Ces régions cérébrales sont respectivement reconnues pour le contrôle cognitif et l'aptitude à orchestrer les pensées, mémorisation des tâches tactiles ou visuelles et les mouvements volontaires des membres.

5.2. Synthèse globale

En globalité, ce rapport a permis de contextualiser notre problématique, à savoir déterminer si le Machine Learning permet de prédire les détériorations comportementales et cérébrales induites par la vieillesse. Nous avons vu en particulier que le vieillissement de la population est une question majeure sociétale qui va nous préoccuper ces prochaines décennies. En parallèle, les avancées technologiques ont permis d'appliquer les algorithmes de ML, autrefois réservés à une sphère d'initiés ayant accès à des super calculateurs. Le mariage de ces deux thématiques est le fondement sur lequel s'appuie cette problématique.

Ensuite, au travers de l'état de l'art, nous avons parcouru les concepts théoriques liés à la posturographie, à l'IRM, à l'imagerie motrice ainsi que l'observation d'action et au ML. Nous avons également pris connaissance des compréhensions actuelles au niveau de la recherche traitant de la sénescence et du ML. Il est apparu que la problématique qui nous intéresse n'a pas encore été traitée par la communauté scientifique, à savoir la mise en relation des données comportementales et cérébrales afin de prédire les détériorations. Dans cette partie, certains choix ont été retenus quant aux régions cérébrales à traiter et les algorithmes de ML à explorer.

Puis, dans la partie « méthodologie », nous nous sommes intéressés aux processus de KDD et avons retenu CRIS-DM. La méthodologie d'acquisition des données ainsi que la classification du type de travail sont également présentées. Cette partie se termine par une comparaison des plateformes de ML et expose les raisons du choix qui s'est orienté vers Knime.

Suite à cela, les analyses et développements nécessaires à atteindre nos objectifs ont été conduits. Pour ce faire, une analyse initiale des données a été opérée, introduisant les bases permettant la préparation des données pour le ML. Il s'en est suivi six itérations visant à améliorer les résultats, dont la synthèse a été présentée en amont du présent paragraphe. Une limitation majeure pour améliorer les résultats a été un nombre de sujets insuffisants. Parmi les meilleurs résultats, nous retrouvons le classificateur à réseaux de neurones artificiels, ce qui est très intéressant puisque nous traitons des données basées sur les activités neuronales qui elles, ne sont pas artificielles.

5.3. Conclusion

Cette étude a permis d'être un pionnier dans le domaine du Machine Learning lié aux troubles des liaisons cérébrales, de la sénescence et l'équilibre. Les résultats peuvent être considérés, à juste titre, comme une base de recherche sérieuse pour un éventuel doctorat ou personne intéressée par ce thème.

Une prochaine étude pourrait consister en une étude longitudinale visant à entraîner les sujets avec des tâches d'équilibre et d'observer si le Machine Learning permettrait de détecter un changement de classe amené par les effets de l'entraînement ou par les traitements médicamenteux. Il serait en outre possible d'y intégrer de l'apprentissage profond (Deep Learning en anglais) qui combine à la fois différents algorithmes de Machine Learning et qui optimise les paramètres internes de ces derniers pour une meilleure prédiction. De plus, le Deep Learning permettrait d'explorer de nouvelles pistes permettant une meilleure classification de l'équilibre que celle basée sur un seuil. Pour cela, une approche basée sur les clusters pourrait par exemple être envisagée. A terme, cela permettrait de déboucher sur une phase aboutie permettant un déploiement d'outils à destination des spécialistes médicaux, en accord avec la dernière phase du CRISP-DM qui n'a pas pu être effectuée, car elle sort du cadre du présent travail.

A des fins de pré-diagnostic, les résultats de ce travail peuvent être intégrés dans les programmes de placement et de soins des seniors. Par exemple, la nécessité ou non de placer une personne dans une structure médico-sociale, hôpital ou le maintien à domicile avant même que l'état de la personne ne devienne sérieux ou critique. Ainsi, nous pouvons désormais affirmer que le ML permet bel est bien de prédire les détériorations comportementales et cérébrales induites par la vieillesse.

Knime est un outil complexe qui contient une multitude des fonctionnalités. Un certain nombre d'itérations sont obligatoires avant de pouvoir utiliser les fonctionnalités plus avancées nécessaires à la réalisation du travail. Toutefois, il faut reconnaître un bon nombre de qualités à ce logiciel sous réserve de corrections des bugs dans les versions ultérieures, mais il n'est pas à douter que la communauté va s'y atteler pour augmenter la qualité de ce logiciel.

Lors de la réalisation de ce travail, nous nous sommes rendu compte de l'importance du facteur humain par rapport à une certaine forme d'efficacité technique apportée par le Machine Learning. Outre les très bons résultats observés lors de diverses itérations, nous avons tout de même pu constater que la machine n'est pas exempte d'erreurs, à l'instar des 10% d'erreurs résiduelles mal classées par Knime. Aussi, baser un diagnostic aveuglément et uniquement sur des interprétations statistiques ne peut être effectué sans l'intervention des spécialistes du domaine. La technique n'est pas une réponse universelle, comme nous avons pu le voir également avec les patients ne pouvant pas utiliser l'IRM. En outre, il faut garder à l'esprit que toute avancée technologique n'est pas à l'abri de mauvaises utilisations dépassant le cadre de la Morale et de l'Ethique (conflit d'intérêts, utilisation de données médicales sans consentement par les assurances, etc.) L'exploitation des progrès technologiques nécessite avant tout la bonne utilisation de la Pensée humaine.

Attestation

Je déclare sur l'honneur, que j'ai effectué ce Travail de Master seul, sans autre aide que celles dûment signalées dans les références, et que je n'ai utilisé que les sources expressément mentionnées.

Lausanne, le 29 août 2016

Ranjith Steve Sivagnanaselvam

6. Références

- [1] Abbruzzese, G., Avanzino, L., Marchese, R., & Pelosin, E. (2015). Action Observation and Motor Imagery: Innovative Cognitive Tools in the Rehabilitation of Parkinson's Disease. *Parkinson's disease*, 2015.
- [2] Ashburner, J. (2007). A fast diffeomorphic image registration algorithm. *Nuroimage*, 38(1), 95-113.
- [3] Azevedo, A., & Santos, M. F. (2008). Kdd, semma crisp-dm: a parallel overviee. *IADIS European Conference Data Mining*.
- [4] Bernardi, G., Carpentier, M., Di Chiara, G., Morelli, M., & Stanzione, P. (2012). *The Basal Ganglia III*. Springer Science & Business Media.
- [5] Bradley, A. P. (1996). The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern recognition*, 30(7), 1145-1159.
- [6] Brink, H., Van der Walt, C., & Van Rensburg, G. (2006). *Fundamentals of Research Methodology for Health Care Professionals*. Lansdowne Cape Town: Juta and Company Ltd.
- [7] Burciu, R. G., Fritsche, N., Granert, O., Schmitz, L., Spönemann, N., Konczak, J., . . . Timmann, D. (2013). Brain changes associated with postural training in patients with cerebellar degeneration: a voxel-based morphometry study. *The Journal of Neuroscience*, 33(10), 4594-4604.
- [8] Chapman, P., Clinton, J., Kerber, R., Reinartz, T., Shaerer, C., & Wirth, R. (2000). CRISP-DM 1.0 Step-by-step data mining guide. *The CRISP-DM consortium*.
- [9] Clark, D. G., McLaughlin, P. M., Woo, E., Hwang, K., Hurtz, S., Ramirez, L., . . . Apostolova, L. G. (2016). Novel verbal fluency scores and structural brain imaging for prediction of cognitive outcome in mild cognitive impairment. *Alzheimer's & Dementia: Diagnosis, Assessment & Disease Monitoring*, 113-122.
- [10] Clark, D. L., Boutros, N. N., & Mendez, M. F. (2010). *The Brain and Behavior: An Introduction to Behavioral Neuroanatomy*. Cambridge University Press.
- [11] Clausi, S., Bozzali, M., Leggio, M., Di Paola, M., Hagberg, G. E., Caltagirone, C., & Molinari, M. (2009). CLAUSI, S., BOZZALI, M., LEGGIO, M. G., et al. Quantification of gray matter changes in the cerebral cortex after isolated cerebellar damage: a voxel-based morphometry study. *Neuroscience*, 162(3), 827-835.
- [12] Confédération suisse (OFS). (2016). *Fondements et vues d'ensemble - Protection des données - Procédé d'anonymisation*. Consulté le 1er août, 2016, sur Office fédéral de la statistique: <http://www.bfs.admin.ch/bfs/portal/fr/index/themen/00/08/blank/04.html>
- [13] Davis, J., & Goadrich, M. (2006). The relationship between Precision-Recall and ROC curves. *Proceedings of the 23rd international conference on Machine learning*, 233-240.
- [14] DeLong, M., & Wichmann, T. (2007). Circuits and circuit disorders of the basal ganglia. *Archives of neurology*, 64(1), 20-24.
- [15] Diener, H.-C., & Dichgans, J. (1992). Pathophysiology of cerebellar ataxia. *Movement Disorders*, 7(2), 95-109.
- [16] Donalek, C. (s.d.). *Supervised and Unsupervised Learning*. Consulté le 23 juillet, 2016, sur Astro Caltech: www.astro.caltech.edu/~george/aybi199/Donalek_Classif.pdf
- [17] Duarte, M., & Freitas, S. M. (2010). Revision of posturography based on force plate for balance evaluation. *Brazilian Journal of physical therapy*, 14(3), 183-192.
- [18] Fayyad, U., Pietetsky-Shapiro, G., & Smyth, P. (1996). From data mining to knowledge discovery in databases. *AI magazine*, 37.

- [19] Friston, K. J., Holmes, A. P., Worsley, K. J., Poline, J., Frith, C. D., & Frackowiak, R. S. (1994). Statistical parametric maps in functional imaging: a general linear approach. *Human brain mapping*, 2(4), 189-210.
- [20] Gashler, M., Giraud-Carrier, C., & Martinez, T. (2008). Decision tree ensemble: Small heterogeneous is better than large homogeneous. *Seventh International Conference on Machine Learning and Applications* (pp. 900-905). IEEE.
- [21] Gollhofer, A., Taube, W., & Nielsen, J. B. (2013). *Routledge Handbook of Motor Control and Motor Learning*. London: Routledge.
- [22] Guo, D., Qiu, T., Bian, J., Kang, W., & Zhang, L. (2009). A computer-aided diagnostic system to discriminate SPIO-enhanced magnetic resonance hepatocellular carcinoma by a neural network classifier. *Computerized Medical Imaging and Graphics*, 33(8), 588-592.
- [23] Hanley, J. A., & McNeil, B. J. (1982). The meaning and use of the area under a receiver operating characteristic (ROC) curve. *Radiology*, 143(1), 29-36.
- [24] Harris, J. A., Miniussi, C., Harris, I. M., & Diamond, M. E. (2002). Transient Storage of a Tactile Memory Trace in Primary Somatosensory Cortex. *The Journal of Neuroscience*, 22(19), 8720-8725.
- [25] Ilg, W., Synofzik, M., Brötz, D., Burkard, S., Giese, M. A., & Schöls, L. (2009). Intensive coordinative training improves motor performance in degenerative cerebellar disease. *Neurology*, 73(22), 1823-1830.
- [26] Jiang, J., Trundle, P., & Ren, J. (2010). Medical image analysis with artificial neural networks. *Computerized Medical Imaging and Graphics*, 34(8), 617-631.
- [27] Knime GmbH. (2016). *Tree Ensemble Learner*. Consulté le 14 août, 2016, sur Knime: https://www.knime.org/files/nodedetails/_labs_treeensemble_Tree_Ensemble_Learner.html
- [28] Kriesel, D. (2007). *A Brief Introduction to Neural Networks*. Consulté le 24 juillet, 2016, sur dkriesel: http://www.dkriesel.com/_media/science/neuronalenetze-en-zeta2-2col-dkrieselcom.pdf
- [29] Lemon, S. C., Roy, J., Clark, M. A., Friedmann, P. D., & Rakowski, W. (2003). Classification and regression tree analysis in public health: Methodological review and comparison with logistic regression. *Annals of behavioral medicine*, 26(3), 172-181.
- [30] Mazzara, G. P., Velthuisen, R. P., Pearlman, J. L., Greenberg, H. M., & Wagner, H. (2004). Brain tumor target volume determination for radiation treatment planning through automated MRI segmentation. *International Journal of Radiation Oncology* Biology* Physics*, 59(1), 300-312.
- [31] Miller, E. K., & Cohen, J. D. (2001). An integrative theory of prefrontal cortex function. *Annual review of neuroscience*, 24(1), 167-202.
- [32] Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hil.
- [33] Mitchell, T. M., Carbonell, J. G., & Michalski, R. S. (2012). *Machine Learning: A Guide to Current Research*. Springer Science & Business Media.
- [34] Morton, S. M., & Bastian, A. J. (2007). Mechanisms of cerebellar gait ataxia. *The Cerebellum*, 6(1), 79-86.
- [35] Muenchen, B. (2015, 30 mars). *Fastest Growing Software for Scholarly Analytics: Python, R, KNIME....* Consulté le 17 juillet, 2016, sur r4stats.com: <http://r4stats.com/2015/03/30/fastest-growing-analytics-2015/>
- [36] Mulder, T. (2007). Motor imagery and action observation: cognitive tools for rehabilitation. *Journal of Neural Transmission*, 114(10), 1265-1278.
- [37] Murphy, M. C., Poplawsky, A. J., Vazquez, A. L., & Chan, K. C. (2016). Improved spatial accuracy of functional maps in the rat olfactory bulb using supervised machine learning approach. *NeuroImage*.

- [38] Nair, S. R., Tan, L. K., Ramli, N. M., Lim, S. Y., Rahmat, K., & Nor, H. M. (2013). A decision tree for differentiating multiple system atrophy from Parkinson's disease using 3-T MR imaging. *European radiology*, 23(6), 1459-1466.
- [39] Nieuwenhuijzen, P. H., Horstink, M. W., Bloem, B. R., & Duysens, J. (2005). Startle responses in Parkinson patients during human gait. *Experimental brain research*, 171(2), 215-224.
- [40] Papegaaij, S., Taube, W., Baudry, S., Otten, E., & Hortobagyi, T. (2014). Aging causes a reorganization of cortical and spinal control of posture. *Frontiers in aging neuroscience*, 6, 28.
- [41] Pedrycz, W., Succi, G., & Stillitti, A. (2016). *Computational Intelligence and Quantitative Software Engineering*. Springer.
- [42] Pickering, J. W. (2015). *What is the value of the area under the roc curve (AUC) to conclude that a classifier is excellent?* Consulté le 1 août, 2016, sur ResearchGate: https://www.researchgate.net/post/What_is_the_value_of_the_area_under_the_roc_curve_AUC_to_conclude_that_a_classifier_is_excellent
- [43] Poldrack, R. A., Mumford, J. A., & Nichols, T. E. (2011). *Handbook of Functional MRI Data Analysis*. New York: Cambridge University Press.
- [44] Priddy, K. L., & Keller, P. E. (2005). *Artificial Neural Networks: An Introduction*. Bellingham, Washington USA: SPIE Press.
- [45] Provost, F. (2000). Machine learning from imbalanced data sets 101. *Proceedings of the AAAI'2000 workshop on imbalanced data sets*, 1-3.
- [46] Quinlan, R. J. (1993). *C4.5: Programs for Machine Learning*. Morgan Kaufmann Publishers.
- [47] Riehle, A., & Vaadia, E. (2004). *Motor Cortex in Voluntary Movements: A Distributed System for Distributed Functions*. CRC Press.
- [48] Saint-Pierre, F. (2007). Analyse de la posture statique et/ou dynamique sur plate-forme de force. *Haute Autorité de Santé*.
- [49] Sanes, J. N., & Donoghue, J. P. (2000). Plasticity and primary motor cortex. *Annual review of neuroscience*, 23(1), 393-415.
- [50] Saraswathi, S., Mahanand, B. S., Kloczkowski, A., Suresh, & Sundarajan, N. (2013). Detection of onset of Alzheimer's disease from MRI images using a GA-ELM-PSO classifier. *Computational Intelligence in Medical Imaging (CIMI)*, 42-48.
- [51] Schmid Botkine, C., & Rausa-de Luca, F. (2008). *Vieillesse démographique et adaptations sociales*. Neuchâtel: Office fédéral de la statistique.
- [52] Seidler, R. D., Bernard, J. A., Burutolu, T. B., Fling, B. W., Gordon, M. T., Gwin, J. T., . . . Lipps, D. B. (2010). Motor control and aging: links to age-related brain structural, functional, and biochemical effects. *Neuroscience & Biobehavioral Reviews*, 34(5), 721-733.
- [53] Seimetz, C., Tan, D., Katayama, R., & Lockhart, T. (2012). A comparison between methods of measuring postural stability: force plates versus accelerometers. *Biomedical sciences instrumentation*, 48, 386.
- [54] Shearer, C. (2000). The CRISP-DM model: the new blueprint for data mining. *Journal of data warehousing*, 13-22.
- [55] Smith, S. M., Jenkinson, M., Woolrich, M. W., Beckmann, C. F., Behrens, T. E., Johansen-Berg, H., . . . Matthews, P. M. (2004). Advances in functional and structural MR image analysis and implementation as FSL. *Neuroimage*, 23, 208-219.
- [56] Super, H., Spekrijse, H., & Lamme, V. (2001). A neural correlate of working memory in the monkey primary visual cortex. *Science*, 293(5527), 120-124.

- [57] Tape, T. G. (2001). *The Area Under an ROC Curve*. Consulté le 1 août, 2016, sur Interpreting Diagnostic Tests - University of Nebraska Medical Center: <http://gim.unmc.edu/dxtests/ROC3.htm>
- [58] Taube, W., Mouthon, M., Leukel, C., Hoogewoud, H.-M., Annoni, J.-M., & Keller, M. (2015). Brain activity during observation and motor imagery of different balance tasks: An fMRI study. *Cortex*, 64, 102-114.
- [59] Taubert, M., Draganski, B., Anwander, A., Müller, K., Horstmann, A., Villringer, A., & Ragert, P. (2010). Dynamic properties of human brain structure: learning-related changes in cortical areas and associated fiber connections. *The Journal of Neuroscience*, 30(35), 11670-11677.
- [60] Taubert, M., Villringer, A., & Ragert, P. (2012). Learning-Related Gray and White Matter Changes in Humans : An Update. *The Neuroscientist*, 18(4), 320-325.
- [61] Tia, B., Mourey, F., Ballay, Y., Sirandré, C., Pozzo, T., & Paizis, C. (2010). Improvement of motor performance by observational training in elderly people. *Neuroscience letters*, 480(2), 138-142.
- [62] Turgeon, M. L. (2014). *Linne & Ringsrud's Clinical Laboratory Science: The Basics and Routine Techniques*. Maryland Heights: Elsevier Health Sciences.
- [63] Vidayanathan, M., Clarke, L. P., Velthuisen, R. P., Phuphanich, S., Bensaïd, A. M., Hall, L. O., . . . Silbiger, M. (1995). Comparison of supervised MRI segmentation methods for tumor volume determination during therapy. *Magnetic resonance imaging*, 13(5), 719-728.
- [64] Vinay, L., Ben-Mabrouk, F., Brocard, F., Clarac, F., Jean-Xavier, C., Pearlstein, E., & Pflieger, J.-F. (2005). Perinatal Development of the Motor Systems Involved in Postural Control. *Neural Plasticity*, 12(2-3), 131-139.
- [65] Visser, J. E., & Bloem, B. R. (2005). Role of the Basal Ganglia in Balance Control. *Neural plasticity*, 12(2-3), 161-174.
- [66] Wollseifen, T. (2011). Different methods of calculating body sway area. *Pharmaceutical Programming*(4), 91-106.
- [67] Zhang, J., Yan, B., Huang, X., Yang, P., & Huang, C. (2008). The diagnosis of Alzheimer's disease based on voxel-based morphometry and support vector machine. *Fourth International Conference on Natural Computation* (pp. 197-201). IEEE.
- [68] Zhou, Y.-D., & Fuster, J. M. (1996). Mnemonic neuronal activity in somatosensory cortex. *Proceedings of the National Academy of Sciences*, 93(19), 10533-10537.

7. Liste des tableaux

| | |
|--|----|
| Tableau 1 - Comparaison des méthodes d'apprentissages supervisés et non supervisés..... | 7 |
| Tableau 2 - Algorithmes retenus et leurs propriétés..... | 8 |
| Tableau 3 - Matrice de confusion..... | 8 |
| Tableau 4 - Classement des AUC selon (Tape, 2001)..... | 9 |
| Tableau 5 - Etapes du KDD..... | 15 |
| Tableau 6 - Correspondances entre KDD, SEMMA et CRISP-DM..... | 16 |
| Tableau 7 - Paramètres et traitements d'acquisition des données IRM..... | 20 |
| Tableau 8 - Vue d'ensemble du jeu de données initial..... | 24 |
| Tableau 9 - Résultats itération 1 fMRI AOP-Repos..... | 30 |
| Tableau 10 - Résultats itération 1 fMRI AOP-AOS..... | 31 |
| Tableau 11 - Résultats itération 1 sMRI..... | 31 |
| Tableau 12 - Région cérébrale retenue avec les données sMRI..... | 32 |
| Tableau 13 - Résultats itération 2 fMRI AOP-Repos..... | 34 |
| Tableau 14 - Résultats itération 2 fMRI AOP-AOS..... | 34 |
| Tableau 15 - Résultat retenu itération 2 fMRI AOP-Repos..... | 35 |
| Tableau 16 - Résultats retenus itération 2 fMRI AOP-AOS..... | 35 |
| Tableau 17 - Classificateurs retenus et leurs paramètres..... | 36 |
| Tableau 18 - Résultats itération 3 fMRI AOP-Repos..... | 37 |
| Tableau 19 - Résultats itération 3 fMRI AOP-AOS..... | 37 |
| Tableau 20 - Résultats itération 3 sMRI..... | 38 |
| Tableau 21 - Résultats itération 4 fMRI AOP-Repos et sMRI..... | 39 |
| Tableau 22 - Résultats itération 4 fMRI AOP-AOS et sMRI..... | 39 |
| Tableau 23 - Rappel des 2 meilleurs résultats..... | 40 |
| Tableau 24 - Instances mal classées du meilleur résultat n° 1..... | 40 |
| Tableau 25 - Instances mal classées du meilleur résultat n° 2..... | 41 |
| Tableau 26 - Itérations sur les paramètres des forêts d'arbres décisionnels pour les données sMRI..... | 42 |

8. Liste des figures

| | |
|--|----|
| Figure 1- Pyramide des âges entre 2006 et 2050 selon le rapport de l'OFS de 2007..... | 1 |
| Figure 2 - Centre de pression, sujet sur une plaque de force..... | 3 |
| Figure 3 - Sway path..... | 3 |
| Figure 4 - Plaque de force et axes de mesure..... | 4 |
| Figure 5 - Exemple de graphes de COPap et COPml..... | 4 |
| Figure 6 - Changements des matières grises et blanches après entraînement de l'équilibre..... | 5 |
| Figure 7 - Visualisation fMRI selon trois orientations..... | 5 |
| Figure 8 - Activités cérébrales durant l'imagerie motrice et l'observation d'action..... | 6 |
| Figure 9 - Courbe ROC..... | 9 |
| Figure 10 - Courbe gaussienne avec SD (68%) et CI (95%)..... | 10 |
| Figure 11 - Régions cérébrales fonctionnelles..... | 12 |
| Figure 12 - Processus de découverte de connaissance..... | 15 |
| Figure 13 - Phases itératives du modèle CRISP-DM..... | 17 |
| Figure 14 - Données brutes des mesures comportementales..... | 19 |
| Figure 15 - Progression des articles académiques par outil d'analyse des données..... | 21 |
| Figure 16 - Statistiques sur le sway path..... | 22 |
| Figure 17 - Boxplot sur les données relatives à l'équilibre..... | 22 |
| Figure 18 - Extrait d'un fichier fMRI..... | 23 |
| Figure 19 - Exemple de fichier sMRI..... | 23 |
| Figure 20 - Histogramme représentant la répartition des sway paths en mm entre les sujets..... | 25 |
| Figure 21 - Extrait de classification de l'équilibre par sujet..... | 25 |

| | |
|--|----|
| Figure 22 - Représentation de l'équilibre des classes..... | 26 |
| Figure 23 - Préparation et nettoyage des données fMRI en vue du ML..... | 27 |
| Figure 24 - Flux Knime de préparation des données fMRI..... | 27 |
| Figure 25 - Préparation et nettoyage des données sMRI en vue du ML..... | 28 |
| Figure 26 - Flux Knime de préparation des données sMRI..... | 29 |
| Figure 27 - Flux de Machine Learning, itération de prise en mains..... | 30 |
| Figure 28 - Nettoyage basé sur la moyenne et l'écart-type des attributs..... | 32 |
| Figure 29 - Flux de préparation pour filtrage du bruit des données fMRI..... | 33 |
| Figure 30 - Flux de Machine Learning avec différents classificateurs..... | 37 |
| Figure 31 - Flux de préparation pour base de données contenant fMRI et sMRI..... | 38 |

9. Liste des équations

| | |
|--|----|
| Équation 1 - COP antéro-postérieur..... | 4 |
| Équation 2 - COP média-latéral..... | 4 |
| Équation 3 – Calcul de la précision..... | 8 |
| Équation 4 - Calcul du rappel..... | 8 |
| Équation 5 – Taux de vrais positifs..... | 9 |
| Équation 6 – Taux de faux positifs..... | 9 |
| Équation 7 - Classification mauvais équilibre..... | 25 |
| Équation 8 - Classification bon équilibre..... | 25 |

10. Annexes

10.1. Critères d'exclusion pour la participation à l'étude

Ci-dessous sont repris les critères d'exclusion pour la participation à l'étude :

- Les personnes avec des blessures orthopédiques sévères
- Les personnes ayant des crises d'épilepsie ou des antécédents familiaux de crises d'épilepsie
- Les participants ayant un ou des implants dans le corps (stimulateur cardiaque, pompe à insuline, vis et plaques consécutives à une fracture...)
- Les personnes susceptibles d'avoir un éclat métallique dans l'œil ou dans le corps (éclat d'obus, balle,...)
- Personnes ayant souffert d'une attaque cérébrale ou de dérèglements neurologiques (également dans le passé)
- Personnes ayant un traumatisme crânien sévère dans le passé
- Personnes ayant des problèmes cardiaques graves
- Personnes souffrant d'agoraphobie (claustrophobie)
- Personnes ayant des tatouages (peut contenir des composés ferro-magnétiques)

10.2.Extraits vidéos des conditions AOP et AOS

Extrait de la vidéo pour la condition s'imaginer contrer une perturbation dynamique (AOP) :



Extrait de la vidéo pour la condition s'imaginer effectuer une tâche d'équilibre statique (AOS) :



10.3. Aide postée sur le forum Knime

Ci-dessous un extrait de l'aide postée sur le forum Knime (<https://tech.knime.org/forum/knime-general/cannot-open-statistics-configuration-view-with-big-csv-file>) :

[Login or register](#) to post comments [Last post](#) 3 posts / 0 new

Wed, 07/06/2016 - 10:21 #1

s.siva
Offline
Joined: 07/06/2016

Cannot open statistics configuration view with big csv file

Hi All

I have a simple workflow consisting of a CSV Reader, a Row filters and Statistics node. The csv file has 31 rows and 139631 columns. I then select some rows with the filter and the resulting table has 9 rows and 139631 columns.

I would like then to see the statistics on the column (mean, standard-deviation) and I use the Statistics node but when I double-click on this node the configuration window does not pop up and Knime does not respond any more event after 8 hours.

I have already tried to increase the amount of Ram memory allocated (up to 12 GB) and the 4 cores of the processor are not fully used (less than 50%) so this seems not to be a limitation of my computer.

Do you have any idea on how to get around this limitation? I have included the Knime workflow as attached file. Unfortunately, I cannot attach the csv file which is bigger (35MB) than the maximum allowed size.

Thank you for your help.

| Attachment | Size |
|----------------------------------|----------|
| fmri_stat_wb.zip | 14.48 KB |

[Top](#)

[Login or register](#) to post comments

Tags: [KNIME General](#)

Wed, 07/06/2016 - 12:07 #2

aborg
Offline
Joined: 07/07/2008

An idea: filter out the numeric columns before connecting the Statistics node to your wide table (I assume there will not many columns remain). Configure the Statistics node (use the include option for nominal values). Change the connection to use the wide table, add a note around the node to "NOT open the configuration" and execute it without opening the configuration. This will most probably solve your problem.

Cheers, gabor

[Top](#)

[Login or register](#) to post comments

Wed, 07/06/2016 - 15:06 #3

s.siva
Offline
Joined: 07/06/2016

Hi gabor

Thank you very much for your hints. It works like a charm. It took 1 hour to do the calculations but at least I am no more blocked with the configuration window not showing up.

Great support, thank you again !

[Top](#)

[Login or register](#) to post comments