



MASTER ATIAM



MÉMOIRE DE STAGE

---

# Systemes interactifs par apprentissage actif pour la reconnaissance de gestes

---

*Auteur:*  
Téo SANCHEZ

*Encadrant:*  
Baptiste CARAMIAUX, chercheur  
CNRS

réalisé au sein de l'équipe

ExSitu  
Laboratoire de Recherche en Informatique



Juillet 2018



SORBONNE UNIVERSITÉ

# Résumé

Université Paris Saclay  
Laboratoire de Recherche en Informatique

Master 2

## Systèmes interactifs par apprentissage actif pour la reconnaissance de gestes

par Téo SANCHEZ

Les systèmes interactifs d'apprentissage machine, où l'humain fournit des exemples au fur et à mesure que la machine apprend, sont complexes et difficiles à évaluer. En même temps que le système apprend de l'humain, l'humain adapte aussi ses exemples aux retours d'informations du système. Dans ce travail, nous incorporons un modèle d'apprentissage actif dans un système interactif. Un algorithme d'apprentissage actif est autorisé à choisir les données à partir desquelles il apprend en posant des requêtes à un «oracle», un humain dans notre cas, qui connaît la nature du problème ou de la tâche à accomplir. Dans un cadre interactif, les requêtes de l'apprentissage actif constituent un retour d'information supplémentaire qui offre à l'humain la possibilité d'appréhender les limites du système et de s'adapter en conséquence. Comprendre ces mécanismes subtils de co-adaptation est un défi.

Dans ce travail, nous présentons deux expériences basées sur une tâche de classification de gestes.

La première expérience exclut l'«humain dans la boucle» d'apprentissage pour évaluer le comportement et les performances de la méthode d'apprentissage actif.

La seconde expérience est une expérience interactive où l'on évalue à la fois les performances objectives mais aussi la perception et l'adaptation de l'humain aux retours d'information du système d'apprentissage actif. Les modèles sont entraînés sur des données gestuelles réalisées par l'humain.

Nous observons que la stratégie d'apprentissage non-agnostique basée sur l'incertitude du modèle permet un apprentissage plus efficace dans les premières requêtes qu'une stratégie agnostique ou aléatoire. Nous montrons aussi comment les requêtes de cette stratégie concordent avec la perception qu'a l'humain des lacunes du système. Enfin, nous exposons comment les participants adaptent leur choix de geste en fonction de leur perception des lacunes du système.

**Mots-clés** : Interaction Humain Machine - Apprentissage Machine Interactif - Apprentissage Actif - Gestes



# Remerciements

Je remercie chaleureusement mon encadrant Baptiste Caramiaux, pour m'avoir confié ce projet très intéressant et pour m'avoir soutenu dans l'obtention d'une bourse doctorale sous son encadrement. Je le remercie aussi pour son enthousiasme, sa gentillesse et sa disponibilité. Ses précieux conseils, sa rigueur et les nombreuses discussions que nous avons eues ont été d'une grande aide.

Je remercie aussi tous les membres de l'équipe ExSitu, dont le dynamisme et la sympathie instaurent une ambiance de travail agréable. Je remercie particulièrement la directrice de l'équipe Wendy Mackay, qui incarne le dynamisme de l'équipe. Merci à Abby, Jean-Philippe, Carla, German, Nolwenn, Stacy, Sally et Nicolas pour leur accueil. Merci à Miguel, Viktor, Yi, Jiannan et Dimitri avec qui je vais avoir le plaisir de travailler dans les années à venir. Merci aux participants de la seconde expérience que je ne peux pas citer.

Merci à l'équipe pédagogique d'ATIAM de proposer des cours et des projets très intéressants. Je remercie particulièrement Benoît Fabre pour son suivi et son aide tout au long de mon master.

Je remercie mes parents pour leur soutien, et surtout mon père pour son intérêt dans mes travaux et les discussions qui en découlent. Merci à la Fondation Deutsch de la Meurthe qui m'a offert un havre de paix à Paris ainsi qu'un cadre de vie et de travail exceptionnel. Merci à Armine pour sa présence quotidienne. Merci à Géraldine pour sa patience et sa précieuse compagnie.



# Table des Matières

<b>1</b>	<b>Introduction</b>	<b>1</b>
<b>2</b>	<b>État de l'art</b>	<b>4</b>
2.1	Apprentissage Actif . . . . .	4
2.1.1	Buts et usages de l'apprentissage actif . . . . .	4
2.1.2	Scénarios d'acquisition des données non-étiquetées . . . . .	5
2.1.3	Stratégies d'apprentissage actif . . . . .	6
	Stratégies agnostiques . . . . .	6
	Stratégies non-agnostiques . . . . .	8
	Stratégies hybrides ou alternées . . . . .	10
2.1.4	Sélection active de classe . . . . .	12
2.1.5	Performances de l'apprentissage actif . . . . .	12
2.2	Apprentissage Machine Interactif . . . . .	13
2.2.1	Reconnaissance de gestes . . . . .	14
2.2.2	Apprentissage Actif avec un humain «dans la boucle» pour la reconnaissance de geste . . . . .	14
2.3	Contributions . . . . .	15
<b>3</b>	<b>Première Étude : Évaluation des méthodes d'apprentissage actif</b>	<b>17</b>
3.1	Méthode . . . . .	17
	Choix du vocabulaire de gestes . . . . .	17
	Participants . . . . .	17
3.1.1	Apparatus . . . . .	17
	Dispositif matériel . . . . .	17
3.1.2	Dispositif logiciel . . . . .	18
	Données gestuelles collectées . . . . .	18
3.1.3	Protocole . . . . .	19
	Collecte des données . . . . .	19
	Analyses . . . . .	20
3.2	Résultats . . . . .	21
3.3	Discussion . . . . .	24
<b>4</b>	<b>Seconde Étude : Apprentissage Actif Interactif de gestes de la main</b>	<b>26</b>
4.1	Méthode . . . . .	26
4.1.1	Participants . . . . .	27
4.1.2	Apparatus . . . . .	27
	Dispositif matériel et logiciel . . . . .	27
4.1.3	Procédure . . . . .	27
4.2	Résultats . . . . .	31
4.2.1	Performances objectives de classification . . . . .	31
4.2.2	Performances de classification perçues . . . . .	32
4.2.3	Comportement des stratégies d'apprentissage actif . . . . .	33
	Lien entre les performances perçues et le choix des requêtes . . . . .	33

Évolution de l'ensemble d'entraînement . . . . .	35
Lien entre la confusion du système et le choix des requêtes . . . . .	36
4.2.4 Adaptation des participants . . . . .	37
4.2.5 Adaptation du système aux individualités . . . . .	38
4.3 Discussion . . . . .	41
4.3.1 Différences entre l'apprentissage actif «avec et sans un humain dans la boucle». . . . .	41
4.3.2 Lien entre les performances objectives et les requêtes. . . . .	41
4.3.3 Lien entre l'incertitude perçue et les requêtes de l'apprentissage actif. . . . .	42
4.3.4 Adaptation de l'humain à l'incertitude perçue. . . . .	42
<b>5 Conclusion</b> . . . . .	<b>44</b>
5.1 Résumé des contributions . . . . .	44
5.2 Perspectives . . . . .	45
<b>Bibliographie</b> . . . . .	<b>46</b>
<b>Liste des Figures</b> . . . . .	<b>50</b>
<b>A Fiche d'évaluation donnée aux participants de la seconde étude</b> . . . . .	<b>51</b>
<b>B Analyse préliminaire de la première étude</b> . . . . .	<b>52</b>



# Liste des abréviations

<b>ANOVA</b>	<b>AN</b> alysis <b>O</b> f <b>V</b> ariance
<b>ATU</b>	<b>A</b> gnostic <b>T</b> raining <b>U</b> tility
<b>AUC</b>	<b>A</b> rea <b>U</b> nder the <b>C</b> urve
<b>DT</b>	<b>D</b> ecision <b>T</b> ree
<b>KNN</b>	<b>K</b> - <b>N</b> earest <b>N</b> eighbors
<b>IHM</b>	<b>I</b> nteraction <b>H</b> umain- <b>M</b> achine
<b>IML</b>	<b>I</b> nteractive <b>M</b> achine <b>L</b> earning
<b>ML</b>	<b>M</b> achine <b>L</b> earning
<b>NB</b>	<b>N</b> aive <b>B</b> ayes
<b>RF</b>	<b>R</b> andom <b>F</b> orest
<b>SVM</b>	<b>S</b> upport <b>V</b> ector <b>M</b> achine
<b>TU</b>	<b>T</b> raining <b>U</b> tility



# Chapitre 1

## Introduction

Dans un contexte créatif tel que la musique, la danse ou le dessin, les mouvements du corps sont un moyen d'expression primaire dont dispose l'humain pour interagir avec son environnement. En plus d'être expressif, l'exécution d'un geste évolue avec la pratique.

Par ailleurs l'Interaction Humain-Machine moderne met de plus en plus en avant le besoin de capturer l'expressivité des utilisateurs. Dans le contexte de l'IHM, un ordinateur pourrait être capable de caractériser l'expressivité des mouvements réalisés par un humain et de lui donner un retour d'information approprié. Il est nécessaire de concevoir des méthodes qui permettent à la machine de modéliser des mouvements spécifiques de l'utilisateur et d'en capturer les caractéristiques les plus fines. L'apprentissage machine est une approche intéressante puisqu'elle permet de modéliser des comportements complexes à partir d'exemples. Cependant, les algorithmes de reconnaissances les plus utilisés et les plus simples effacent toutes variations expressives et individuelles.

Pour pallier ce problème, une approche est de mettre l'humain dans la boucle d'apprentissage. L'apprentissage machine interactif (IML) permet à l'utilisateur de concevoir des interactions complexes à partir d'exemples au lieu d'une programmation explicite (Fiebrink and Caramiaux, 2016, Françoise, 2015). Le processus est généralement itératif : l'utilisateur montre des gestes que le système doit reconnaître, puis l'utilisateur essaie ses capacités de reconnaissance avec de nouvelles entrées gestuelles, avant de revenir en phase d'apprentissage pour modifier les paramètres du modèle avec de nouveaux gestes. Cette méthodologie interactive d'apprentissage machine demande à l'utilisateur d'itérer le processus, c'est à dire de revenir à différentes phases du processus d'apprentissage.

Pour modifier le système, l'utilisateur s'appuie uniquement sur une interprétation du fonctionnement et des capacités du système, généralement au travers des prédictions de celui-ci. De plus, les interactions possibles pour en modifier le comportement sont limitées et consistent la plupart du temps à adapter les exemples donnés.

Nous sommes intéressés par d'autres retours d'information provenant du système et d'autres moyens d'interaction, en vue d'améliorer l'apprentissage et de rendre le système plus «transparent» pour l'utilisateur. On propose une approche active où l'utilisateur et la machine «convergent» vers un classifieur de geste optimal et personnalisé.

L'objectif de ce travail est d'étudier les systèmes interactifs d'apprentissage actif pour la reconnaissance de gestes. Dans un premier temps, il est important de comprendre les avantages et les inconvénients des techniques d'apprentissage actif en dehors d'un contexte d'interaction, avant d'inclure un humain dans «la boucle» d'apprentissage. Conjointement, ce travail cherche à étudier l'humain et de comprendre comment il perçoit et interagit avec le système lors de l'apprentissage.

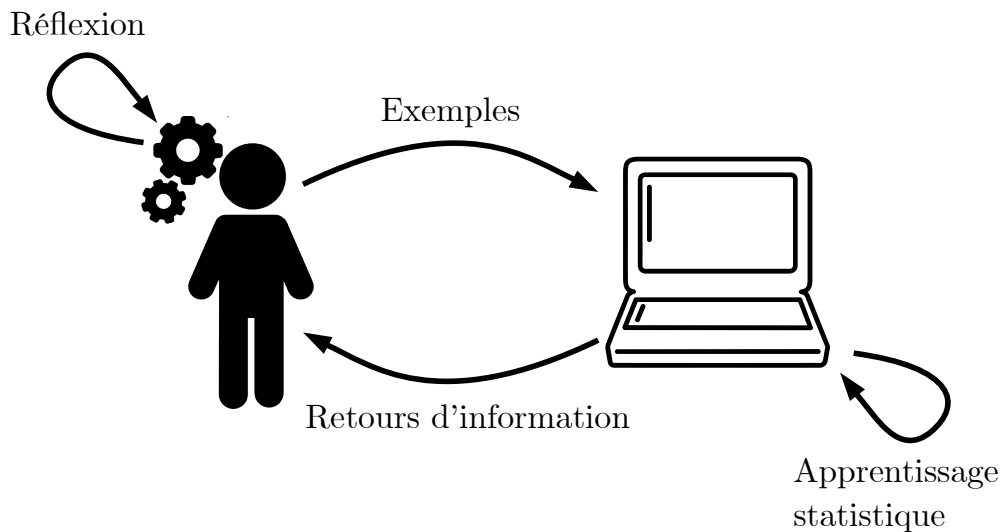


FIG 1.1: Rétroactions lors d'un processus d'apprentissage machine interactif.

Ces recherches, centrées à la fois sur la machine et sur l'humain, aideront à mettre à jour des stratégies de collaborations entre l'humain et la machine et pourront servir les avancées théoriques en prise de décision, traitement de l'incertitude et en acquisition de compétence.

Pour résumer, les principaux objectifs de ce travail sont:

1. Quelles sont les différences entre un système d'apprentissage actif sans agent humain et avec agent humain, du point de vue des performances algorithmiques?
2. Comment se comportent les stratégies d'apprentissage actif pour des données gestuelles, dans un contexte interactif ou non.
3. Quelle perception et quelle compréhension ont les participants des limites et de la confusion du système?
4. Quelles sont les adaptations des participants aux retours d'information du système sur ses capacités de classification?
5. Comment les stratégies automatiques d'apprentissage actif se comportent-elles en présence d'un agent humain? Est-ce que les retours d'informations du système d'apprentissage actif ont du sens pour l'humain?

Les méthodes d'apprentissage actif (Settles, 2009) ont la capacité d'apprendre de façon incrémentale à travers une plus petite quantité de données en choisissant stratégiquement l'ordre des entrées.

À chaque étape, l'apprentissage actif cherche à sélectionner l'entrée la plus informative afin d'apprendre plus efficacement et avec une plus petite quantité de données.

Pour choisir l'ordre des exemples, le système d'apprentissage actif soumet des requêtes à un «oracle» (comme un utilisateur humain par exemple). L'«oracle» est l'entité qui va étiqueter les requêtes du système.

L'apprentissage machine interactif<sup>1</sup> (IML) implique un humain et un algorithme d'apprentissage automatique qui interagissent via une interface afin de réaliser une tâche

<sup>1</sup>Interactive Machine Learning

and Olsen Jr, 2003. L'interaction permet d'identifier et de corriger des erreurs au cours du processus d'apprentissage puisque la base d'entraînement se construit au fil de l'interaction avec l'utilisateur. Cette approche donne plus de pouvoir à l'utilisateur pendant le processus d'apprentissage. L'idée est de permettre à l'utilisateur de corriger l'apprentissage de la machine à sa guise en agissant sur les exemples qu'il donne au système.

Dans ce travail, on se place dans un contexte d'«apprentissage actif interactif» où l'«oracle» qui répond aux requêtes est l'utilisateur. Comme en IML, la base d'entraînement servant de support aux requêtes de l'apprentissage actif se construit au fil de l'interaction..

Dans ce contexte, les requêtes sont des retours d'information supplémentaires qui permettent à l'utilisateur d'appréhender les capacités du système. Ces retours d'information modifient à leur tour la façon dont l'utilisateur va enseigner le système. Par exemple, l'utilisateur peut adapter le choix ou la réalisation de ses gestes. Ces rétroactions entre l'humain et la machine, schématisées sur la figure 1.1, donnent lieu à de nombreuses questions de recherches qui peuvent être abordées à la fois du point de vue des performances algorithmiques d'apprentissage et du point de vue de la perception de l'humain et de son adaptation au système.

D'une part, le système s'adapte à l'humain en entraînant un modèle d'apprentissage automatique sur les exemples que l'humain lui donne. D'autre part, l'humain réfléchit sur ses propres exemples en fonction des lacunes ou des qualités du système qu'il perçoit. Ce sont ces rétro-actions que nous cherchons à comprendre et qui se complexifient en incluant l'apprentissage actif dans les retours d'information de la machine.

Les systèmes interactifs d'apprentissage actif pourraient être appliqués à des processus créatifs, où l'objectif n'est pas défini à l'avance mais évolue au cours de l'interaction. Ces systèmes pourraient également être utilisés pour l'aide à l'acquisition de compétence (dans la rééducation motrice par exemple), en ciblant avec précision les retours d'informations pertinents.

On présentera d'abord l'état de l'art autour de l'apprentissage actif et de l'apprentissage machine interactif. Les travaux sont ensuite structurés autour des deux expériences réalisées:

La première, présentée dans le chapitre 3, n'inclut pas un humain dans la boucle de l'apprentissage. Même si elle repose sur des données gestuelles, cette expérience exclut l'influence d'un humain dans la boucle simplifiant ainsi les rétroactions présentées en figure 1.1. Simplifier le problème permet de mieux comprendre le comportement des stratégies d'apprentissage actif et permet de comparer les résultats obtenus à ceux de la littérature sur l'apprentissage actif.

À partir des résultats de cette première expérience, une seconde expérience interactive a été réalisée et sera présentée dans le chapitre 4. Elle présente des résultats portant sur les performances objectives et perçues de classification, sur le comportement des stratégies d'apprentissage actif, sur l'adaptation des participants au système et du système aux participants. Enfin, les résultats des deux expériences seront discutés et mis en regard avec ceux de la littérature.

## Chapitre 2

# État de l'art

### 2.1 Apprentissage Actif

Les systèmes d'apprentissage machine classiques<sup>1</sup> sont capables d'améliorer progressivement les performances d'une tâche spécifique si des exemples représentatifs du comportement face à cette tâche sont fournis au système. Ces méthodes permettent de concevoir des algorithmes avec un comportement spécifique sans utiliser de programmation explicite. C'est généralement une configuration où les données sont d'abord collectées puis encodées en paquet pour être apprises par le système. L'apprentissage machine imite l'apprentissage naturel en ajustant automatiquement un modèle mathématique afin de simplifier la complexité du problème, en utilisant par exemple un traitement probabiliste des données.

L'apprentissage naturel humain est souvent plus rapide et plus durable lorsque le sujet qui apprend agit, questionne et fait des expériences sur son environnement au lieu d'assimiler passivement les informations qu'il reçoit (Freeman, 1965, Prince, 2004). Bien qu'il soit risqué de vouloir comparer les mécanismes de l'apprentissage machine et humain, des techniques imitant l'apprentissage actif humain ont été développés pour l'apprentissage machine. L'apprentissage actif<sup>2</sup> en informatique, est un ensemble de modèles d'apprentissage semi-supervisés où l'algorithme d'apprentissage demande des informations, contrairement au cadre classique où les données sont connues d'emblée. En choisissant stratégiquement l'ordre des instances d'entrées à questionner, on attend de ces algorithmes qu'ils obtiennent de meilleures performances avec moins d'instances d'entraînement. L'apprenant (la machine) «pose des questions» à un «oracle». Généralement, les requêtes ont la forme d'instances d'entrées dont l'«oracle» (un annotateur humain ou artificiel) fournit la sortie correspondante (Settles, 2009).

#### 2.1.1 Buts et usages de l'apprentissage actif

Afin d'entraîner un modèle d'apprentissage machine, les instances d'entrées et leurs sorties correspondantes doivent être fournies au système. Le modèle sera alors en mesure de généraliser sur de nouvelles entrées grâce à un entraînement préalable. Comme nous l'avons mentionné dans la partie précédente, la pratique la plus courante en apprentissage machine consiste à fournir plus de données au modèle (entrées et sorties correspondantes) afin de continuer à améliorer les performances. L'apprentissage actif s'inspire de l'apprentissage naturel,

---

<sup>1</sup>Machine Learning en anglais.

<sup>2</sup>«Active learning» en anglais.

en proposant des algorithmes qui peuvent sélectionner des instances et interroger un agent extérieur<sup>3</sup> sur ces instances. Il repose sur l'hypothèse que l'apprentissage est plus efficace lorsque l'on est curieux, en cherchant les données les plus informatives et les plus pertinentes à annoter.

Les premiers modèles sont développés au début des années 90 (Cohn, Atlas, and Ladner, 1994), et ont été utilisés pour l'optimisation de la conception expérimentale<sup>4</sup> (Cohn, 1994) : l'algorithme choisit les paramètres optimaux pour une expérience à réaliser. Le résultat de cette expérience affecte la prochaine requête d'expérience. Cela permet de minimiser le nombre d'expériences, qui peuvent être parfois coûteuses, afin de modéliser un phénomène plus rapidement.

Le modèle d'apprentissage machine sous-jacent, appelé apprenant<sup>5</sup>, s'améliore aussi efficacement qu'en apprentissage machine classique mais avec moins de données grâce à un «plan» d'apprentissage, c'est à dire une organisation de l'ordre des instances à apprendre. C'est en planifiant l'apprentissage que l'on espère obtenir de meilleures performances plus rapidement.

L'apprentissage actif peut s'adapter à la plupart des tâches classiques dans le domaine de l'apprentissage automatique telles que la classification ou la régression. Ces méthodes ont été appliquées à divers modèles, classifieurs simples (Pereira-Santos, Prudêncio, and Carvalho, 2017) ou réseaux profonds (Gal, Islam, and Ghahramani, 2017), et à une grande variété de problèmes réels tels que la reconnaissance vocale (Zhu, Lafferty, and Rosenfeld, 2005), la recherche d'images (Feng et al., 2012), la prédiction de fonctions protéiques Xiong et al., 2014, ou la tomographie (Maiora, Ayerdi, and Graña, 2014) entre autres.

L'«oracle» est chargé de fournir la sortie correspondante à une entrée demandée par le système. Dans le cas d'une tâche de classification, la sortie est appelée étiquette. Nous limiterons la portée de ce travail et de l'état de l'art à une tâche de classification.

### 2.1.2 Scénarios d'acquisition des données non-étiquetées

La façon dont le modèle sélectionne les instances d'entrée est dépendante du scénario d'acquisition et de l'accessibilité des données non-étiquetées. On distingue généralement trois scénarios, également décrits par Settles, 2009 dans sa revue de littérature sur l'apprentissage actif:

- **Requêtes par synthèse**<sup>6</sup> (Angluin, 1988) : le modèle peut générer des instances à étiqueter de novo (Settles, 2009). Les instances sont généralement synthétisées dans un espace de paramètre. Par exemple, un modèle physique paramétrique peut générer de nouvelles instances en faisant varier le choix des paramètres du modèle<sup>7</sup>. L'oracle serait le modèle physique et les requêtes du système seraient des paramètres. Ce scénario ne reflète

---

<sup>3</sup>On retrouve aussi le terme «oracle» dans la littérature relative à l'apprentissage actif. C'est à dire, une entité humaine ou artificielle, qui fournit la réponse à la requête de l'algorithme sur ces instances. Par exemple, dans un problème de classification, l'algorithme sélectionne une instance non-étiquetée et l'«oracle» fournit l'étiquette correspondante.

<sup>4</sup>«Optimal Experiment Design» (OED) en anglais.

<sup>5</sup>«Learner» en anglais.

<sup>6</sup>«Membership Query Synthesis» en anglais.

<sup>7</sup>Analogie avec le projet appliqué à la musique en ATIAM : on utilise les échantillons générés par le modèle physique de clarinette pour cartographier l'espace défini par la pression dans la bouche du musicien et la pression des lèvres sur l'anche (Missoum, Vergez, and Doc, 2014).

pas une distribution sous-jacente naturelle des données puisque le système est libre d'en synthétiser de nouvelles.

- **Échantillonnage sélectif de flux de données**<sup>8</sup> (Atlas, Cohn, and Ladner, 1990, Cohn, Atlas, and Ladner, 1994) : Cette fois-ci, les données sont un flux c'est à dire une suite d'éléments traitée séquentiellement. L'hypothèse de ce scénario est qu'une instance non étiquetée est peu coûteuse mais accessible temporairement. Pour chaque élément, le modèle peut décider de demander son étiquette ou de rejeter l'élément. Dans ce scénario, la distribution sous-jacente des instances générées est généralement non-uniforme et inconnue.
- **Échantillonnage par réserve**<sup>9</sup> (Lewis and Gale, 1994) : dans ce scénario, les instances non-étiquetées sont stockées et sont toutes accessibles lors de la sélection. Ce scénario fait l'hypothèse que l'ensemble des données étiquetées  $\mathcal{L}$  est petit comparé à l'ensemble des données non-étiquetées  $\mathcal{U}$ . Les instances (ou requêtes) sont choisies dans la réserve  $\mathcal{U}$ , qui est généralement fermée, à partir d'une stratégie définie.

La stratégie de sélection des instances est dépendante du scénario d'acquisition des données. En effet, dans l'échantillonnage par réserve, on peut appliquer un critère sur tous les échantillons de la réserve à la fois, ce qui est impossible dans l'échantillonnage sélectif de flux de données. Il est important de noter que les deux scénarios de requêtes par synthèse et échantillonnage sélectif de flux de données peuvent être réduits à un échantillonnage par réserve, simplement en stockant les données générées.

Dans la suite, on limitera notre étude au scénario d'échantillonnage par réserve.

### 2.1.3 Stratégies d'apprentissage actif

«««< HEAD Une fois que l'ensemble  $\mathcal{L}$  d'instances non-étiquetés est réunie, l'algorithme doit choisir l'instance engendrant la plus grande amélioration du modèle à l'itération suivante. Comment quantifier le potentiel informatif d'une instance? Différentes stratégies ont été développés pour sélectionner l'instance la plus pertinente. Ces stratégies peuvent être regroupées selon deux heuristiques (Pereira-Santos, Prudêncio, and Carvalho, 2017) décrits dans les parties ci-dessous.

===== Une fois que l'ensemble  $\mathcal{L}$  d'instances non-étiquetées est réuni, l'algorithme doit choisir l'instance engendrant la plus grande amélioration du modèle à l'itération suivante. Comment quantifier le potentiel informatif d'une instance? Différentes stratégies ont été développées pour sélectionner l'instance la plus pertinente. Ces stratégies peuvent être regroupées selon deux approches (Pereira-Santos, Prudêncio, and Carvalho, 2017) décrites dans les parties ci-dessous.

»»»> 6c7c079b4f91545031136f7a9b2de5f33f5fa822

On décrira des stratégies d'apprentissage actif de manière non-exhaustives qui s'appliquent au scénario d'échantillonnage par réserve.

#### Stratégies agnostiques

«««< HEAD Ces stratégies dépendent uniquement de la «réserve» des instances non-étiquetées  $\mathcal{U}$  et étiquetées  $\mathcal{L}$ . L'exactitude de la frontière de décision du modèle n'influence pas le choix de

<sup>8</sup>«Stream-Based Selective Sampling» en anglais.

<sup>9</sup>«Pool-based Sampling» en anglais.



l'instance à interroger. Le terme agnostique est utilisé pour signifier que la stratégie s'adapte aux instances qu'elle sélectionne. Parmi ces stratégies on peut citer:

**L'échantillonnage aléatoire :** Cette stratégie est simplement un choix aléatoire d'une instance dans l'ensemble  $\mathcal{U}$ . Elle sert de configuration de contrôle puisqu'il ce choix correspond à une absence de stratégie de sélection. Cependant, pour un grand nombre de requêtes, la distribution sous-jacente des instances de l'ensemble  $\mathcal{U}$  sera conservée.

**L'échantillonnage par densité :** Le postulat de cette stratégie (et de ses variantes) est que les instances les plus pertinentes ne doivent pas seulement être celles qui sont ambiguës, mais aussi celles qui sont représentatives de la distribution sous-jacente de l'ensemble  $\mathcal{U}$  (Settles, 2009). Ces stratégies reposent donc sur la distribution des instances dans l'espace des données non-étiquetées. Ces stratégies permettent d'éviter la sélection d'instances aberrantes<sup>10</sup>, non représentatives de la distribution sous-jacente des instances. Dans la plupart des cas, elles sélectionnent des instances dans les régions denses de l'espace  $\mathcal{U}$ . Une mesure de distance est calculé entre tous les éléments de  $\mathcal{U}$ . Cette distance est l'une des variables de cette stratégie. Dans notre cas, on se limitera à des distances euclidiennes.

=====

Ces stratégies dépendent uniquement de la réserve des instances non-étiquetées  $\mathcal{U}$  et étiquetées  $\mathcal{L}$ . L'exactitude de la frontière de décision du modèle n'influence pas le choix de l'instance à interroger. Le terme agnostique est utilisé pour signifier que la stratégie s'adapte aux instances qu'elle sélectionne. Parmi ces stratégies on peut citer :

**L'échantillonnage aléatoire (Random) :** Cette stratégie est simplement un choix aléatoire d'une instance dans l'ensemble  $\mathcal{U}$ . Elle sert de configuration de contrôle pour les autres stratégies. En moyenne, la stratégie aléatoire a des performances équivalente à l'apprentissage par paquet et peut être vu comme un absence d'organisation dans l'ordre des données à entraîner. Pour un grand nombre de requêtes, la distribution sous-jacente des instances de l'ensemble  $\mathcal{U}$  sera conservée. »»»»> 6c7c079b4f91545031136f7a9b2de5f33f5fa822

**L'échantillonnage par densité :** Le postulat de cette stratégie (et de ses variantes) est que les instances les plus pertinentes ne doivent pas seulement être celles qui sont ambiguës, mais aussi celles qui sont représentatives de la distribution sous-jacente de l'ensemble  $\mathcal{U}$  (Settles, 2009). Ces stratégies reposent donc sur la distribution des instances dans l'espace des données non-étiquetées. Ces stratégies permettent d'éviter la sélection d'instances aberrantes<sup>11</sup>, non représentatives de la distribution sous-jacente des instances. Dans la plupart des cas, elles sélectionnent des instances dans les régions denses de l'espace  $\mathcal{U}$ . Une mesure de distance est calculée entre tous les éléments de  $\mathcal{U}$ . Cette distance est l'une des variables de cette stratégie. Dans notre cas, on se limitera à des distances euclidiennes.

Parmi les stratégies par densité, la **méthode agnostique d'utilité d'entraînement par densité**, que l'on appellera par la suite ATU<sup>12</sup> (d'après Dos Santos and Carvalho, 2015) choisit une requête dans  $\mathcal{U}$  selon la distribution des instances dans  $\mathcal{U}$  et  $\mathcal{L}$  simultanément. Elle repose sur une fonction d'«utilité», qui est un terme souvent utilisé en économie désignant une fonction mathématique qui classe des alternatives en fonction de leur utilité pour un individu. Ici, ce sont les instances qui sont classées en fonction de l'utilité pour le modèle d'apprentissage

<sup>10</sup>«Outliers» en anglais

<sup>11</sup>«Outliers» en anglais.

<sup>12</sup>«Density-weighted Agnostic Training Utility Sampling» en anglais.

machine. L'échantillon  $\hat{x}$  sélectionné est celui qui maximise la fonction d'utilité ATU. Il s'écrit :

$$\hat{x} = \operatorname{argmax}_{x \in \mathcal{U}} \left[ \frac{1}{|\mathcal{U}|} \sum_{u \in \mathcal{U}} \operatorname{sim}(x, u) \left( \frac{1}{|\mathcal{L}|} \sum_{l \in \mathcal{L}} \operatorname{sim}(x, l) \right)^{-1} \right] \quad (2.1)$$

avec  $\operatorname{sim}(x, u)$ , une mesure de similarité, qui peut être une distance. Dans notre cas, il s'agira d'une distance euclidienne.

Cette méthode choisit une instance dans  $\mathcal{U}$  qui est à la fois dans une région dense de  $\mathcal{U}$ , et à la fois dans une région clairsemée de  $\mathcal{L}$  (l'ensemble des données étiquetées). En d'autres termes, cette méthode d'échantillonnage favorise à la fois les instances représentatives des instances disponibles (c'est-à-dire qui sous-tendent la distribution de  $\mathcal{U}$ ), et à la fois les instances des régions faiblement étiquetées.

D'autres stratégies agnostiques existent telles que des **stratégies de partitionnement**<sup>13</sup> (Dasgupta, 2011) ou les **stratégies par recherche d'espace d'hypothèse**<sup>14</sup> (Cohn, Atlas, and Ladner, 1994).

Puisque les stratégies agnostiques n'utilisent pas les paramètres courants du modèle, elles peuvent être calculées dès lors que la réserve d'instance non-étiquetée est disponible. Puis ces résultats peuvent être mis en cache pour être utilisés en temps réel lors de l'apprentissage machine interactif.

### Stratégies non-agnostiques

Ces stratégies reposent sur l'état du modèle actuel pour choisir la prochaine requête d'instance. Les paramètres du modèle (dont on peut tirer les probabilités à posteriori d'appartenance à une classe par exemple) sont utilisés pour calculer un score sur chaque instance de  $\mathcal{U}$  afin de déterminer l'instance la plus pertinente pour l'étape en cours. Ces scores doivent être recalculés à chaque ré-entraînement du modèle puisque les paramètres du modèle auront changé. Parmi ces stratégies, on compte :

**L'échantillonnage par incertitude**<sup>15</sup> est en ensemble de méthodes très utilisé en apprentissage actif. Ces méthodes reposent sur l'idée que l'instance pour laquelle l'étiquette prédite est la plus incertaine sera la plus bénéfique pour l'apprentissage. Les méthodes par incertitude utilisent sur les probabilités à posteriori émises par le modèle d'apprentissage machine à un moment donné de son entraînement. Parmi les méthodes par incertitude, on distingue :

L'échantillonnage par minimisation de la probabilité à posteriori maximale (Lewis and Gale, 1994) qui consiste à trouver une instance  $\hat{x}$  dans  $\mathcal{U}$  qui minimise la probabilité à posteriori maximale sur les classes  $Y$ :

$$\hat{x} = \operatorname{argmin}_{x \in \mathcal{U}} \left( \max_{y \in Y} P(y|x) \right) \quad (2.2)$$

Ce critère ne tient pas compte des probabilités calculées pour les autres classes moins probables. Pour des problèmes à plusieurs classes, on a une perte d'information dans cette mesure d'incertitude.

<sup>13</sup> «Cluster-based sampling» en anglais.

<sup>14</sup> «Hypothesis Space Search» en anglais.

<sup>15</sup> «Uncertainty Sampling» en anglais.

L'échantillonnage par minimisation de la «marge»<sup>16</sup> (Scheffer, Decomain, and Wrobel, 2001) qui consiste à considérer les deux plus grandes probabilités à posteriori des échantillons dans  $\mathcal{U}$  et de calculer leur différence, la «marge». On cherche ensuite à sélectionner l'instance de  $\mathcal{U}$  qui minimise cette marge:

$$\mathbf{z}(\mathbf{x}) = \operatorname{argmax}_{y \in \mathcal{Y}} P(y|\mathbf{x}) \quad (2.3)$$

$$M(\mathbf{x}) = P(\mathbf{z}(\mathbf{x})|\mathbf{x}) - \max_{y \in \mathcal{Y} \setminus \{\mathbf{z}(\mathbf{x})\}} (P(y|\mathbf{x})) \quad (2.4)$$

$$\hat{\mathbf{x}} = \operatorname{argmin}_{\mathbf{x} \in \mathcal{U}} (M(\mathbf{x})) \quad (2.5)$$

Dans la suite on appellera cette stratégie la stratégie Margin.

L'échantillonnage par maximisation d'entropie<sup>17</sup> (Shannon, 2001) est une méthode d'échantillonnage par incertitude plus générale que les deux précédentes. Elle se base sur l'entropie de Shannon utilisé en théorie de l'information. L'entropie de Shannon est une mesure théorique qui quantifie la quantité d'information contenue dans une source d'information, ici les instances de  $\mathcal{U}$ . L'entropie est associée à l'incertitude puisque si une distribution de probabilité est équiprobable, son entropie sera maximale (la classe prédite sera incertaine). À l'inverse, si l'une des classes a une probabilité de 1 et les autres sont nulles, alors l'entropie sera nulle. Dans ce cas, l'instance n'apportera pas d'information au modèle<sup>18</sup>. Contrairement à l'échantillonnage par minimisation de la «marge», l'entropie de Shannon tient compte des probabilités sur toutes les classes. Cette mesure de l'incertitude s'écrit:

$$\hat{\mathbf{x}} = \operatorname{argmax}_{\mathbf{x} \in \mathcal{U}} \left( \sum_i P(y_i|x) \log(P(y_i|x)) \right) \quad (2.6)$$

avec  $P(y_i|x)$  représente la probabilité pour une instance donnée  $x$  d'appartenir à la classe  $i$ , selon le modèle courant.

Pour une classification binaire, l'échantillonnage par minimisation de la probabilité à posteriori maximale, par minimisation de la marge et par maximisation d'entropie sont équivalentes.

Bien que la mesure d'entropie soit plus générale que le calcul de la marge ou que le calcul des maxima des probabilités à posteriori, elle n'est pas forcément plus performante pour l'apprentissage actif. Des résultats empiriques comparant ces trois mesures suggèrent que les performances dépendent de l'application considérée (Körner and Wrobel, 2006, Schein and Ungar, 2005 et Settles and Craven, 2008).

La stratégie d'échantillonnage par incertitude peut aussi s'appliquer aux classificateurs non probabilistes comme les SVM (Tong and Koller, 2001), les arbres binaires de décision (Lewis and Catlett, 1994) ou les algorithmes par plus proches voisins (Fujii et al., 1998, Lindenbaum, Markovitch, and Rusakov, 2004).

**Réduction de l'erreur attendue**<sup>19</sup> (Roy and McCallum, 2001) : Cette stratégie non-agnostique cherche à sélectionner l'instance qui minimise l'erreur future attendue sur l'ensemble du modèle. Pour cela, on calcule l'entropie attendue sur l'ensemble des instances non-étiquetées après avoir sélectionné un échantillon de  $\mathcal{U}$ . Puis on choisit l'élément  $\hat{\mathbf{x}}$  qui

<sup>16</sup>«Margin Sampling» en anglais.

<sup>17</sup>«Entropy Sampling» en anglais.

<sup>18</sup>Seulement si les probabilités à posteriori émises étaient exactes or il s'agit d'estimations.

<sup>19</sup>«Expected Error Reduction» en anglais.

minimise ce score. L'échantillon choisit s'écrit:

$$\hat{\mathbf{x}} = \operatorname{argmin}_{\mathbf{x} \in \mathcal{U}} \left[ \sum_i P_\theta(y_i | \mathbf{x}) \left( \sum_{x^* \in \mathcal{U} \setminus \mathbf{x}} 1 - P_{\theta^+(\langle x, y_i \rangle)}(y_i^* | x^*) \right) \right] \quad (2.7)$$

où  $\theta^+(\langle x, y_i \rangle)$  est le nouveau modèle ré-entraîné avec le groupe  $\langle x, y_i \rangle$  ajouté à l'ensemble d'entraînement  $\mathcal{L}$ .

Minimiser l'entropie attendue sur l'ensemble des instances de  $\mathcal{U}$  revient à maximiser l'information mutuelle des variables de sortie sur  $x$  et  $\mathcal{U}$ . L'information mutuelle d'un couple  $(X, Y)$  de variables représente leur degré de dépendance au sens probabiliste (Houlsby et al., 2011). L'information mutuelle est nulle si les variables sont indépendantes, et croît lorsque la dépendance augmente. Les instances qui maximisent l'information mutuelle sont des instances sur lesquelles le modèle est incertain en moyenne. Cette stratégie peut néanmoins entraîner des modèles produisant des prédictions erronées avec une grande certitude (Gal, Islam, and Ghahramani, 2017). Gal, 2016 explique que les méthodes par incertitude (entropie par exemple) présentées à la page 8, capturent l'incertitude dans les prédictions tandis que la méthode de réduction de l'erreur attendue, fondée sur l'information mutuelle, capture quant à elle la confiance du modèle dans ses prédictions.

L'ordre de complexité de la stratégie de réduction de l'erreur attendue est le plus élevé parmi les toutes les stratégies considérées ici. Les méthodes agnostiques ne sont calculées qu'une seule fois au début du processus d'apprentissage (ou à chaque fois qu'un nouvel élément est ajouté à  $\mathcal{U}$ ). Les stratégies non-agnostiques par incertitude ont une complexité en  $\mathcal{O}(|Y||\mathcal{U}|)$  pour chaque requête, avec  $|Y|$  le nombre de classes. La stratégie de réduction de l'erreur attendue a quant à elle un complexité de  $\mathcal{O}(|Y||\mathcal{U}|^2)$  pour chaque requête et un nouveau modèle doit être entraîné  $|\mathcal{U}|$  fois (un modèle  $\theta^+(\langle x, y_i \rangle)$  pour chaque élément  $x$  de  $\mathcal{U}$ ). Cette complexité rend cette stratégie difficilement applicable dans un contexte interactif où la taille de  $\mathcal{U}$  est importante.

Une variante appelé réduction optimiste de l'erreur attendue<sup>20</sup> (Guo and Greiner, 2007) considère la prédiction du modèle courant  $y_i$  comme une étiquette valable lors de l'estimation de l'erreur ( $y_i = y_i^*$ ). Cela évite de ré-entraîner le modèle  $\theta$  avec le couple  $\langle x, y_i \rangle$  et réduit ainsi les temps de calculs. Zhang et al., 2015 ont proposé une stratégie de réduction d'erreur attendue dans les cas où l'ensemble  $Y$  des classes est indéterminé.

### Stratégies hybrides ou alternées

Fujii et al., 1998 proposent une méthode qui combine la méthode ATU (cf. section 2.1.3) avec une méthode non-agnostique d'incertitude<sup>21</sup>. Appelée stratégie d'utilité d'entraînement par densité<sup>22</sup> (TU), elle choisit l'échantillon de  $\mathcal{U}$  qui maximise le produit entre la fonction d'utilité ATU et le calcul d'incertitude à partir des probabilités à posteriori du modèle courant (Margin ou Entropie par exemple). L'échantillon  $\hat{\mathbf{x}}$  de  $\mathcal{U}$  sélectionné s'écrit:

$$\hat{\mathbf{x}} = \operatorname{argmax}_{\mathbf{x} \in \mathcal{U}} \left[ \operatorname{uncertainty}(\mathbf{x}) \left( \frac{1}{|\mathcal{U}|} \sum_{\mathbf{u} \in \mathcal{U}} \operatorname{sim}(\mathbf{x}, \mathbf{u}) \right)^\alpha \left( \frac{1}{|\mathcal{L}|} \sum_{\mathbf{l} \in \mathcal{L}} \operatorname{sim}(\mathbf{x}, \mathbf{l}) \right)^{-\gamma} \right] \quad (2.8)$$

<sup>20</sup>Optimistic Error Reduction (OER)

<sup>21</sup>Ce qui en fait tout de même une stratégie non-agnostique puisqu'elle utilise le modèle courant

<sup>22</sup>Density-weighted Training Utility

avec «uncertainty», une des mesures de l'incertitude présentée à la page 8,  $\text{sim}(x, l)$ , une mesure de similarité ou une distance, qui peut être calculée avant le début de l'apprentissage actif.  $\alpha$  et  $\gamma$  pondèrent la contribution de la densité relative des instances de  $\mathcal{U}$  et  $\mathcal{L}$  respectivement.

Dos Santos and Carvalho, 2015 présentent une méthode hybride d'utilité d'entraînement par densité<sup>23</sup> (HTU). HTU calcule à la fois la fonction d'utilité de TU et d'ATU sur les échantillons de  $\mathcal{U}$  durant le processus d'apprentissage actif. Une corrélation de Pearson est ensuite calculée sur les résultats de TU et ATU sur  $\mathcal{U}$ . Une forte corrélation (proche de 1) indique une faible contribution de la partie exploratoire de TU à la requête. Cette corrélation peut être utilisée comme seuil pour utiliser tour à tour ATU ou TU (Pereira-Santos, Prudêncio, and Carvalho, 2017).

Ferdowsi, Ghani, and Kumar, 2011 ont aussi développé une méthode qui estime les performances de plusieurs stratégies au cours de l'apprentissage et peut basculer d'une stratégie à l'autre à tout moment pour maximiser les performances.

Les approches et les stratégies d'apprentissage actif présentées jusqu'à présent sont récapitulés dans la figure 2.1, qui s'inspire d'une figure de l'article de Pereira-Santos, Prudêncio, and Carvalho, 2017.

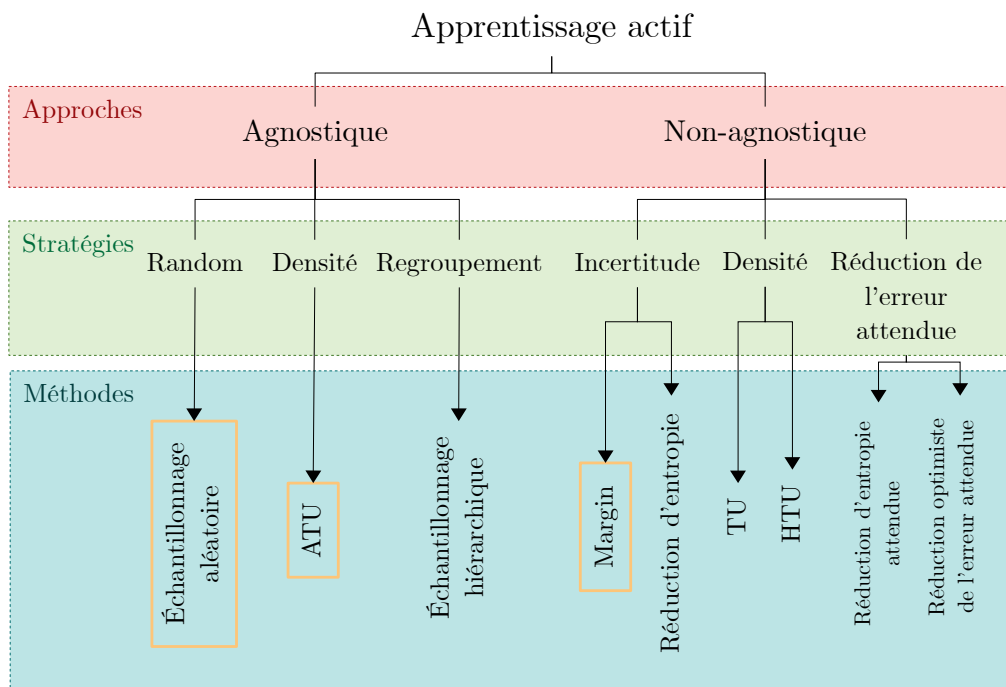


FIG 2.1: Récapitulatif non exhaustif des approches et des stratégies d'apprentissage actif. Les méthodes encadrées en orange sont celles qui seront étudiées dans nos travaux. Leur choix est justifié à la page ??.

<sup>23</sup>«Hybrid Density-based Training Utility»

### 2.1.4 Sélection active de classe

Les méthodes de sélection active de classe <sup>24</sup> (Lomasky et al., 2007, Wu and Parsons, 2011) choisissent leur requêtes en fonction des classes des instances de  $\mathcal{L}$  et celles prédites par le modèle sur l'ensemble  $\mathcal{U}$ . Lomasky et al., 2007 présente 5 méthodes d'ACS qui cherche à répondre à la question suivante : Si l'on devait choisir  $n$  instances d'entraînement supplémentaires, comment devraient-elles être distribuées en fonction des classes? L'une des stratégies utilise le modèle courant pour prédire une classe sur les instances de  $\mathcal{U}$ , puis, pour chaque instance  $x$  de  $\mathcal{U}$ , elle entraîne un nouveau modèle  $\theta^{+x}$  à partir de  $\mathcal{L} \cup x$ . Les  $n$  instances choisies sont celles qui engendrent le plus de changement dans les prédictions sur  $\mathcal{U}$ , entre le modèle  $\theta$  entraîné sur  $\mathcal{L}$  et le modèle  $\theta^{+x}$  entraîné sur  $\mathcal{L} \cup x$ . Cette stratégie suppose que ces instances représentent des frontières volatiles et sélectionne donc les instances engendrant le plus d'instabilité entre deux itérations.

### 2.1.5 Performances de l'apprentissage actif

Ramirez-Loaiza et al., 2017, Pereira-Santos, Prudêncio, and Carvalho, 2017 ont montré que les performances de l'apprentissage actif sont inégales et spécifiques au cas d'application. Ces mêmes auteurs montrent que la plupart des publications en apprentissage actif se concentrent à développer de nouvelles stratégies mais appliquent leurs modèles à des situations restreintes, ne permettant pas de savoir si l'apprentissage actif est plus performant que l'apprentissage classique, en moyenne. Ramirez-Loaiza et al., 2017 et Pereira-Santos, Prudêncio, and Carvalho, 2017 présument que les performances de l'apprentissage actif dépendent de plusieurs facteurs:

- Du modèle d'apprentissage machine utilisé (classifieur).
- De la base de donnée : du nombre de classes et des dimensions.
- De la qualité des réponses de l'«oracle».
- De la mesure de performance.

Pereira-Santos, Prudêncio, and Carvalho, 2017 utilisent 15 stratégies d'apprentissage actif agnostiques ou non, combinées à 5 classifieurs différents. Ils ont ensuite évalué les performances de toutes les combinaisons sur 75 bases de données. Chaque paire de modèle-stratégie est classée, en fonction du nombre de requêtes. Ces résultats ont apporté deux contributions majeures sur l'apprentissage actif.

D'abord, l'apprentissage actif est efficace en moyenne malgré certaines publications mitigées dans la littérature. Ensuite, ils mettent en évidence la prévalence du modèle par rapport aux stratégies d'échantillonnage.

Aucune généralisation ne peut être faite avec une stratégie d'échantillonnage particulière. Chaque cas d'utilisation doit aboutir à une batterie de tests afin de trouver la meilleure paire de modèle et de stratégie d'échantillonnage. Les futurs travaux de Pereira-Santos, Prudêncio, and Carvalho, 2017 seraient d'étudier l'influence des caractéristiques des bases de données sur l'apprentissage actif. Ramirez-Loaiza et al., 2017 montrent que 83% des articles sur l'apprentissage actif n'utilise qu'un seul classifieur et 91% n'utilise qu'une seule mesure de performance. Ils comparent 5 mesures de performances (AUC, Accuracy, Precision, Recall et  $F_1$ ), et montrent qu'une même expérience d'apprentissage actif peut donner des résultats différents selon la mesure utilisée.

---

<sup>24</sup>Active Class Selection (ACS).

À notre connaissance, peu de travaux traitent de l'influence de la qualité de l'oracle sur les performances. Donmez and Carbonell, 2008 et Zhong et al., 2014 étudient des systèmes qui gèrent plusieurs oracles imparfaits, mais cette configuration est en dehors du cadre de notre étude.

## 2.2 Apprentissage Machine Interactif

L'apprentissage machine interactif<sup>25</sup> (IML) implique un humain et un algorithme d'apprentissage automatique qui interagissent via une interface afin de réaliser une tâche Fails and Olsen Jr, 2003. L'humain et le programme peuvent tout deux donner des retours d'information implicites ou explicites.

L'intérêt pour l'IML est multiple. Tout d'abord, il permet de modéliser des connaissances et des comportements experts qu'il serait impossible d'encoder explicitement. Contrairement à l'apprentissage machine classique qui traite les données en paquets, l'interaction permet d'identifier et de corriger des erreurs au cours du processus d'apprentissage en adaptant les exemples. Il donne plus de pouvoir à l'utilisateur pendant le processus d'apprentissage. L'idée est de permettre à l'utilisateur de corriger l'apprentissage de la machine à sa guise. L'IML pourrait ainsi être utilisé pour des applications où la tâche n'est pas définie à l'avance comme la création artistique par exemple. En outre, les algorithmes d'apprentissage automatique sont de plus en plus utilisés dans les domaines de la création, avec des réseaux profonds par exemple. Ces réseaux profonds sont plus expressifs grâce à leur capacité d'abstraction sur des données complexes. Cependant, les nombreuses transformations successives des données en font des «boîtes noires» pour les novices. L'IML pourrait rendre ces outils plus accessibles, compréhensibles et manipulables.

Du point de vue de l'Interaction Humain-Machine (HCI), l'IML est un cas d'interaction intéressant et complexe.

En effet, l'humain donne des retours implicites et explicites au modèle d'apprentissage. Il peut fournir de nouvelles données ou étiqueter des données. Il induit des connaissances spécifiques au système en choisissant les intrants à entraîner. La machine fournit également des retours implicites à l'utilisateur via des prédictions de sortie ou des requêtes d'apprentissage actif. Pour des modèles simples, on peut imaginer des retours d'information explicites via une visualisation de la limite de décision ou via des probabilités de classification sur les données non étiquetées.

Contrairement à la littérature relative à l'apprentissage active, celle relative à l'IML est une source de connaissances et d'outils d'analyses centrés sur l'humain et son comportement vis-à-vis du système (Fiebrink, Cook, and Trueman, 2011, Boukhelifa, Bezerianos, and Lutton, 2018).

Bien que l'apprentissage machine classique se focalise sur le raffinement des modèles, Simard et al., 2017 soutient qu'améliorer les capacités de l'«enseignant» (humain) plutôt que de l'«apprenant» (la machine)<sup>26</sup> pourrait grandement améliorer les performances dans la réalisation d'une tâche, tout en rendant les outils d'apprentissage machine plus accessibles. Ces recherches ouvrent de vastes problématiques à la frontière de l'apprentissage machine et de l'interaction humain-machine.

---

<sup>25</sup>Interactive Machine Learning

<sup>26</sup>«Improving the efficiency of the «teachers» given the «learners»

### 2.2.1 Reconnaissance de gestes

La reconnaissance de geste dispose d'une littérature et d'applications abondantes dans de nombreux domaines : la danse (Fdili Alaoui et al., 2013), le geste musical (Caramiaux, Wanderley, and Bevilacqua, 2012), la robotique (Calinon et al., 2010), les systèmes de contrôle (Freeman and Weissman, 1997) et la médecine (Pogorelc, Bosnić, and Gams, 2012) par exemple.

D'une part, la reconnaissance de geste a permis de concevoir de nouvelles interactions avec la machine. De nombreuses études s'intéressent aux gestes de la main (Rautaray and Agrawal, 2015). Les applications de ces méthodes sont très vastes : elles offrent un substitut à l'utilisation du clavier et de la souris (Iannizzotto, Villari, and Vita, 2001), permettent la manipulation d'objets graphiques (Bolt and Herranz, 1992) et s'appliquent au dessin (Cohen et al., 1997) ou au design.

D'autre part, la reconnaissance de geste peut être appliquée à l'expressivité. La compréhension des caractéristiques implicites et non fonctionnelles d'un geste, comme l'expressivité, reste un défi pour ce domaine. Encoder explicitement ces subtilités est trop complexe et l'apprentissage automatique semble être l'une des méthodes les plus adaptées pour encoder les variations idiosyncratiques de l'exécution des gestes. Les subtilités expressives contenues dans un geste en font un cas d'étude pertinent pour des systèmes d'apprentissage machine interactif. Par exemple, Mancini and Castellano, 2007 s'intéresse à l'analyse et la synthèse en temps réel de gestes expressifs et Caramiaux, Donnarumma, and Tanaka, 2015 s'intéresse à l'expressivité au travers de la tension des muscles.

La reconnaissance de geste est également utilisée avec des systèmes d'apprentissage machine interactif. Françoise, 2013 a étudié l'apprentissage de «mapping» entre des gestes et des sons, à partir des exemples fournis par les utilisateurs tout en interagissant avec le système. Fiebrink, Trueman, and Cook, 2009 ont développé et évalué un logiciel permettant à un utilisateur d'entraîner, de générer des exemples, d'évaluer les résultats et de modifier les paramètres en temps réel d'un modèle d'apprentissage machine.

### 2.2.2 Apprentissage Actif avec un humain «dans la boucle» pour la reconnaissance de geste

L'apprentissage actif pour la reconnaissance de geste permet de rendre la machine plus stratégique dans son adaptation à l'«oracle» humain. L'apprentissage actif rend le système plus transparent pour l'utilisateur puisque les requêtes du système reflètent sa stratégie d'adaptation. L'humain peut à son tour s'adapter au système et cette co-adaptation pourrait permettre de converger plus rapidement vers le classifieur optimal de l'utilisateur.

Dans un système interactif par apprentissage actif, l'«oracle» est un utilisateur humain du système. D'après les notions d'apprentissage actif présenté dans la partie 2.1, le fonctionnement d'un système interactif par apprentissage actif pour une tâche de classification est schématisé sur la figure 2.2.

Comme évoqué dans l'introduction, dans un processus d'apprentissage actif, l'interaction entre l'utilisateur et l'«apprenant» est plus complexe car la machine fournit des retours implicites supplémentaires sur ses connaissances et sa stratégie d'apprentissage active sous-jacente à travers les requêtes adressées à l'utilisateur. Les rétroactions présentées sur la figure 1.1, compliquent l'étude de l'interaction mais augmente les possibilités de concevoir un système interactif qui réalise une tâche donnée de manière efficace et satisfaisante.



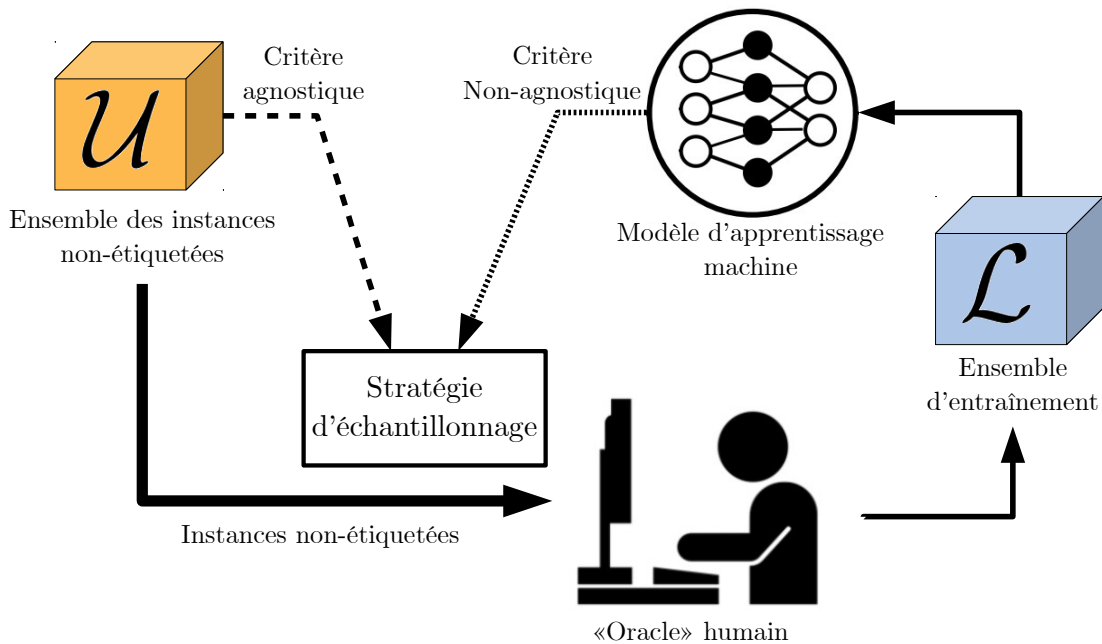


FIG 2.2: Configuration d'apprentissage actif avec un humain dans la boucle. La stratégie d'échantillonnage dépend de l'ensemble  $\mathcal{U}$  dans pour les stratégies agnostiques et dépend du modèle d'apprentissage machine pour les stratégies non-agnostiques.

Au delà de cette étude, l'enjeu est de concevoir des systèmes interactifs d'apprentissage actif qui ne sont pas uniquement basés sur des performances quantitatives centrées sur la machine, mais de prendre aussi en compte la psychologie humaine et la cognition Amershi et al., 2014. Par exemple, le flux de requêtes de l'apprenant peut nuire à l'intérêt de l'utilisateur pour le processus d'apprentissage et l'utilisateur peut alors «perdre la trace de ce qu'il enseignait» Par exemple, Cakmak, Chao, and Thomaz, 2010 utilise l'apprentissage actif pour enseigner des mouvements à un robot. L'une de ses observations est que le flux de requêtes du robot peut nuire à l'intérêt de du participant pour le processus d'apprentissage. Le participant peut alors «perdre la trace de ce qu'il enseignait»<sup>27</sup>. La prise en main des systèmes et le confort de l'humain peuvent influencer le processus d'apprentissage, d'où l'importance de développer des méthodes d'évaluation des systèmes interactifs centrées sur l'humain (Pea, 1986).

Enfin, les systèmes interactif par apprentissage actif devraient non seulement améliorer l'apprentissage automatique et le rendre plus compréhensible, mais ils pourraient également permettre de mieux comprendre la perception et l'adaptation des utilisateurs au système.

## 2.3 Contributions

L'apprentissage actif dans le contexte de la reconnaissance de geste est peu étudié, et son utilisation dans un cadre interactif n'a pas encore été étudié à notre connaissance. Notre étude est une preuve de concept de l'utilisation de l'apprentissage actif dans un système

<sup>27</sup> «Lose track of what they were teaching»

interactif. Elle se limite à une tâche de classification de données gestuelles, comprenant 5 classes et 6 dimensions (accélération et orientation dans les 3 dimension). L'«orcale» est humain et donc imparfait. Nous étudierons sa perception du système et son adaptation, ce qui à notre connaissance, a été peu étudié dans le cadre de l'apprentissage actif.

On propose de commencer par étudier le comportement et les performances de l'apprentissage actif au travers d'une première étude «benchmark» qui n'inclue pas «l'humain dans la boucle». Nous proposons ensuite une seconde étude qui utilise l'apprentissage actif pour la reconnaissance de geste dans un contexte interactif.

Les contributions de ce travail sont:

- La reproduction de l'état de l'art au travers de l'évaluation de l'apprentissage actif sur des ensembles de données ad hoc, et avec un nombre réduit de classes.
- La réalisation d'un système interactif d'apprentissage actif appliqué à des gestes.
- L'évaluation de la perception des limites du système par l'utilisateur.
- L'identification des moyens d'adaptation de l'utilisateur aux capacités du système.

## Chapitre 3

# Première Étude : Évaluation des méthodes d'apprentissage actif

Dans cette première expérience, on collecte des données gestuelles étiquetées pour tester plusieurs modèles d'apprentissage machine et plusieurs stratégies d'apprentissage actif «sans l'humain dans la boucle».

### 3.1 Méthode

#### Choix du vocabulaire de gestes

Plusieurs vocabulaires de gestes ont été essayé. Nous avons finalement opté pour des lettres latines cursives dessinées en l'air avec la main dominante. Ce vocabulaire présente l'avantage de pouvoir étiqueter les gestes avec un seul symbole. De plus, dans un contexte interactif, ce vocabulaire de geste permet d'utiliser jusqu'à 26 classes sans effort de mémoire pour le participant.

#### Participants

La collecte des données a été réalisée par quatre participants âgés en moyenne de 41.5 ans (écart-type de 16.6 ans). On compte parmi ces participants trois hommes et une femme. Tous sont droitiers. Aucun participant n'a de troubles de la vision (sans compter les personnes possédant un appareil de correction visuelle) ou de troubles moteurs ou cognitifs reconnus. 100% d'entre eux ont déjà utilisé des dispositifs de captation de mouvement pour des jeux vidéos. 25% des participants ont une activité liée à l'informatique.

#### 3.1.1 Apparatus

##### Dispositif matériel

Pour la captation de mouvement, on utilise un smart-phone Nexus LG model LG-H791F équipé d'accéléromètres et de gyroscopes. L'interface graphique est présentée sur un ordinateur MacBook Pro. Un clavier externe est utilisé pour que le participant puisse démarrer et arrêter l'enregistrement de ses gestes en appuyant sur un bouton.

La figure 3.1 montre une photographie de la manière dont les participants interagissent avec le dispositif.



FIG 3.1: Photographie du dispositif et d'un individu en train de l'utiliser (non participant). Les données gestuelles sont issues des capteurs du smart-phone. Celles-ci sont envoyées à l'ordinateur qui les enregistre dans un fichier. Le mobile est tenu dans la main dominante de l'utilisateur et la main non-dominante permet de démarrer et d'arrêter l'enregistrement d'un geste.

### 3.1.2 Dispositif logiciel

Pour la collecte des données, le routage des données gestuelles se fait par le biais d'un serveur<sup>1</sup>. Les données issues des capteurs du téléphone sont transmises lorsqu'il est connecté au serveur en tant que client (par le navigateur du téléphone). Ce dernier se charge de découper les gestes quand le participant appuie sur le clavier. Puis le serveur écrit les données dans un fichier.

Après la collecte des données, l'analyse de l'apprentissage actif est programmé en **Python**, et utilisant la librairie **scikit-learn**. Plusieurs types de classifieurs sont utilisés : une machine à vecteurs de support<sup>2</sup> (SVM), un algorithme des k plus proches voisins<sup>3</sup> (KNN), une forêt d'arbres décisionnels<sup>4</sup> (RF) et une classification bayésienne naïve<sup>5</sup> (NB).

#### Données gestuelles collectées

Les données collectées sont les accélérations normalisées entre -1 et 1 et les orientations selon les trois directions (X,Y et Z). L'orientation est calculée à partir des données des

<sup>1</sup>Programmé en NodeJS et utilisant les librairies **mano-js** et **waves-lfo** (développés par Benjamin Matuszewski à l'IRCAM) pour le routage des flux de données

<sup>2</sup>Support Vector Machine

<sup>3</sup>k Nearest Neighbors

<sup>4</sup>Random Field classifier

<sup>5</sup>Naive Bayes

gyroscopes et des accéléromètres <sup>6</sup>. La fréquence d'échantillonnage est de 50 Hz mais les données sont ré-échantillonnées par la méthode de Fourier à la même taille de 40 échantillons. Les données d'un geste sont donc une matrice bi-dimensionnelle de 6 caractéristiques et de longueur 40. Un exemple est tracé sur la figure 3.2.

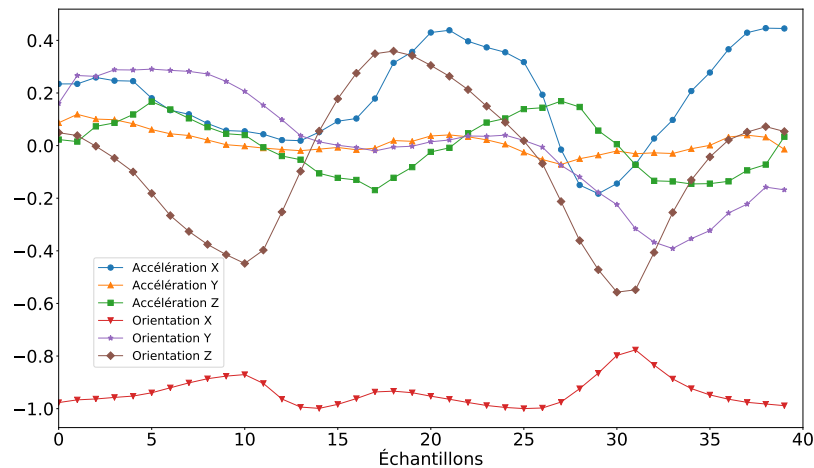


FIG 3.2: Données issues des capteurs, affichées pour un geste.

À chaque participant, on demande de réaliser 50 gestes pour les 5 classes, soit 250 gestes en tout.

### 3.1.3 Protocole

#### Collecte des données

Les consignes données au participant sont:

- Le téléphone mobile doit être tenu dans la main dominante et la main non-dominante doit servir à appuyer sur la touche d'enregistrement.
- Le vocabulaire de geste sont 5 lettres latines - z, m, k, u et p <sup>7</sup> - qui doivent être dessinées en l'air devant soi. Il est précisé que les lettres doivent être écrites de manière personnelle mais en lettre cursive.

La lettre à réaliser est affichée au milieu de l'interface. Un indicateur devient rouge lorsque l'enregistrement est actif. Une barre de progression en bas de l'interface graphique permet de suivre l'avancement de l'expérience <sup>8</sup>.

<sup>6</sup>cf. la [documentation](#) pour plus de détails (operator.Orientation)

<sup>7</sup>Des tests préalables sur les 26 lettres de l'alphabet ont montrés que ces lettres étaient les mieux classifiées (les moins confuses). Les résultats des performances sur cette base de données contenant les 26 lettres de l'alphabet sont disponible en annexe B.

<sup>8</sup>L'interface est presque identique à celle présentée à la figure 4.3.

## Analyses

On réalise deux types d'analyse sur les quatre bases de données récoltées. La première s'intéresse aux performances de classification par validation croisée<sup>9</sup> selon la méthode du «test-set validation». On divise la base de donnée  $\mathcal{B}$  de taille  $N$  en deux sous-ensembles:

- Le premier ensemble  $\mathcal{A}$ , dit «d'apprentissage» est un tirage aléatoire dans l'ensemble  $\mathcal{B}$ . On fixe sa taille à 70% de celle de  $\mathcal{B}$ .
- Le second ensemble  $\mathcal{T}$ , dit «de test», est composé des instances restantes. Il s'agit de l'ensemble  $\mathcal{B}$  moins l'ensemble  $\mathcal{A}$ . Sa taille est de 30% celle de  $\mathcal{B}$ .

L'apprentissage actif est réalisé sur l'ensemble d'apprentissage  $\mathcal{A}$  et validé sur l'ensemble de test  $\mathcal{T}$ . La mesure de performance utilisée sur  $\mathcal{T}$  est le taux de prédiction correcte. Il s'agit du nombre de prédictions correctes sur le nombre total de prédictions (correctes et incorrectes):

$$Score = \frac{Nb_{correctes}}{Nb_{Prédictions}} \quad (3.1)$$

L'ensemble  $\mathcal{A}$  sur lequel on réalise l'apprentissage actif est également divisé en deux ensembles présentés dans l'état de l'art 2.1.2: l'ensemble  $\mathcal{U}$  des instances non étiquetées et l'ensemble  $\mathcal{L}$  des instances étiquetées et sur lesquels le modèle a été entraîné.

Initialement,  $\mathcal{U}$  est de taille 10 (2 instances par classe choisies aléatoirement). Puis, à chaque requête, le tuple de l'instance et de son étiquette est transféré de  $\mathcal{U}$  à  $\mathcal{L}$ . Le modèle est ré-entraîné sur  $\mathcal{L}$  après chaque requête.

Le calcul du taux de prédiction correcte (équation 3.1) est réalisé sur l'ensemble de test  $\mathcal{T}$  après chaque requête. Le nombre maximal de requêtes, appelé budget, varie de 0 à 15 gestes<sup>10</sup>.

On stocke la valeur du taux de prédiction correcte calculé à chaque fois que le budget de requête est atteint. Puis on itère l'opération depuis le début en incrémentant le budget de 1. On repart depuis l'étape de partitionnement de la base de donnée  $\mathcal{B}$  en un ensemble de tests  $\mathcal{T}$  et d'apprentissage  $\mathcal{A}$ . Une fois que le budget atteint sa valeur maximale de 15, on réinitialise le budget à 0 et on réitère 50 fois.

Lorsque l'on évalue plusieurs stratégies d'apprentissage actif, les instances de test pour la validation croisée sont les mêmes entre les stratégies à une itération donnée.

Les ensembles utilisés sont schématisés sur la figure 3.3 et le calcul de la validation croisée est exprimé dans le pseudo-code 3.1.1.



FIG 3.3: Partitionnement de la base de donnée  $\mathcal{B}$  durant la validation croisée. La flèche indique le transfert des instances de l'ensemble  $\mathcal{U}$  à  $\mathcal{L}$  après une requête.

<sup>9</sup>«Cross-validation» en anglais.

<sup>10</sup>La valeur maximale du budget est identique à celui de la seconde étude

---

**Algorithme 3.1.1:** VALIDATION CROISÉE ( $\mathcal{B}, \text{strategies}, \text{budget}_{max} = 15$ )
 

---

```

tableaux scores
pour pas ← 0 jusqu'à 50
  faire
    pour budget ← 0 jusqu'à budgetmax
      faire
        partitionner  $\mathcal{B}$  en  $\mathcal{A}$  et  $\mathcal{T}$  avec  $\text{card}(\mathcal{A}) = 0.7 \times \text{card}(\mathcal{B})$  et  $\text{card}(\mathcal{T}) = 0.3 \times \text{card}(\mathcal{B})$ 
        partitionner  $\mathcal{A}$  en  $\mathcal{U}$  et  $\mathcal{L}$  avec  $\text{card}(\mathcal{L}) = 10$ 
        pour chaque strategies
          faire
            pour j ← 0 jusqu'à budget
              faire
                entraîner  $\theta$  sur  $\mathcal{L}$ 
                choisir la prochaine instance inst selon la stratégie courante
                transférer inst de  $\mathcal{U}$  à  $\mathcal{L}$ 
            variables réelles mesure ← taux de prédictions correctes calculé sur  $\mathcal{T}$ 
            stocker mesure dans scores
          retourne (scores)
  
```

---

Pour chaque participant, on obtient un tableau de taille  $15 \times 50$  pour les 15 tailles du budget et les 50 passes. Les valeurs sont ensuite moyennées sur les passes et entre les participants. Les résultats de ces analyses sont présentés à la section suivante, à la figure 3.4.

La seconde analyse concerne les classes demandées dans les requêtes des stratégies d'apprentissage actif. On trace le nombre d'instances d'une classe dans l'ensemble  $\mathcal{L}$  en fonction du nombre de requêtes. Les résultats de ces analyses sont présentés en figures 3.5 et 3.6.

## 3.2 Résultats

Sur la figure 3.4 sont présentés les résultats de l'analyse des performances expliquée dans la section précédente pour les stratégies Random, Margin et ATU et les modèles SVM, KNN, RF et NB<sup>11</sup>.

On observe des performances de départ et d'arrivée différentes pour les différents modèles. Le modèle SVM obtient les meilleurs scores finaux tandis que le modèle NB obtient la plus grande progression entre les scores initiaux et finaux. NB obtient aussi le plus grand écart de performance entre les stratégies pour les dernières requêtes. Cependant, pour les 4 modèles, l'ordre des performances pour les 3 stratégies reste le même. Margin obtient les meilleures performances et Random les pires quelque soit le modèle.

Dans les figures 3.5 et 3.6 sont tracées les distributions des classes dans l'ensemble d'entraînement  $\mathcal{L}$  en fonction des requêtes, pour un seul participant et moyennés sur les 50

---

<sup>11</sup>Les stratégies TU et de maximisation de l'entropie ont été implémentés mais, par soucis de clarté, on ne présentera pas leurs résultats. La stratégie par entropie donne des résultats similaires à la stratégie Margin (ou légèrement moins bon) et TU donne des performances similaires à ATU. Cela semble cohérent puisque la méthode de maximisation de l'entropie est une généralisation de Margin, et TU est similaire à ATU dans sa définition.

passes.

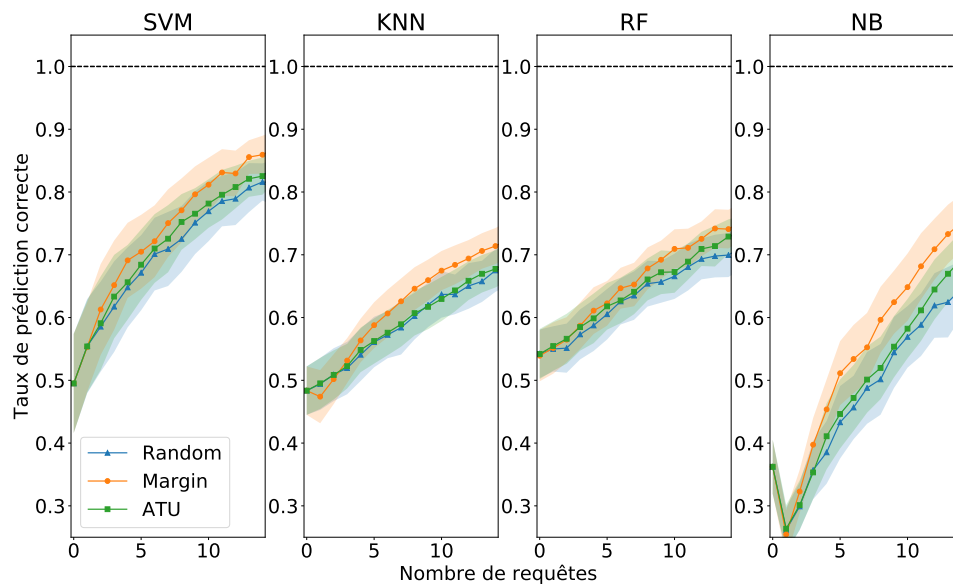


FIG 3.4: Taux de prédiction correcte moyenné sur les participants en fonction du nombre de requêtes pour 3 stratégies d'apprentissage actif (Random, Margin et ATU), 4 classifieurs (SVM, KNN, RF et NB) et pour un ensemble de données composées de 5 lettres cursives de l'alphabet romain (z, m, k, u, p) dessinées en l'air avec la main dominante.






FIG 3.5: Distribution des classes (lettres) lors de l'apprentissage actif sur les données d'un seul participant, pour les trois stratégies (Random, Margin et ATU), pour 2 classifieurs (SVM et KNN) et pour 5 lettres de l'alphabet.

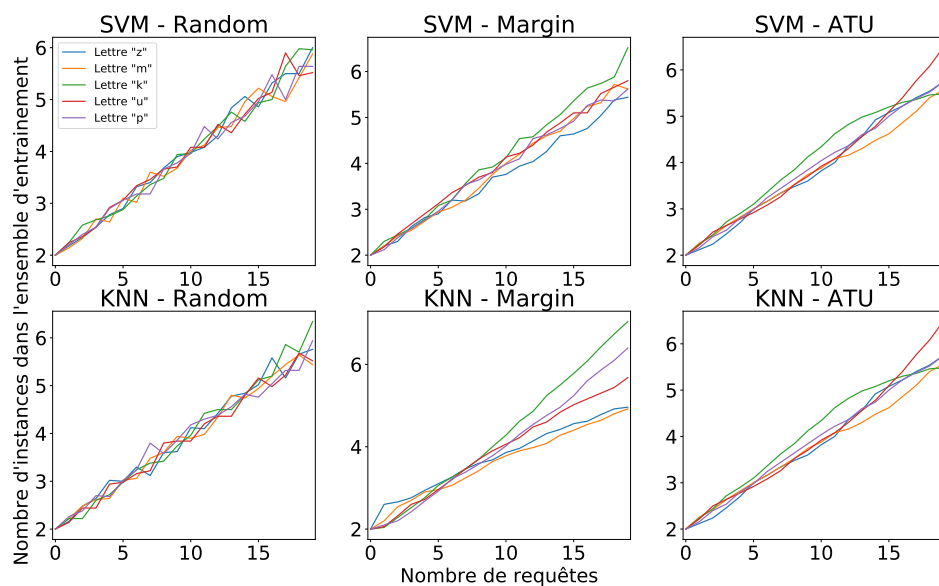


FIG 3.6: Distribution des classes (lettres) lors de l'apprentissage actif sur les données d'un autre participant, pour les trois stratégies (Random, Margin et ATU), pour 2 classifieurs (RF et NB) et pour 5 lettres de l'alphabet.

On peut observer plusieurs comportements:

- La stratégie Random ne favorise aucune classe dans  $\mathcal{L}$  quelques soient le modèle et la stratégie. Cela est cohérent avec la définition de la stratégie Random.
- La stratégie ATU dépend du participant mais pas du modèle. Cela est aussi cohérent avec la définition d'ATU, puisqu'elle ne se base pas sur les probabilités à posteriori émises par le modèle (cf. par exemple la figure 3.5, et les cas SVM-ATU et KNN-ATU).
- Les stratégies Margin et ATU ne donnent pas les mêmes évolutions de distribution de classes dans  $\mathcal{L}$ , pour un même participant et un même modèle. Cela est flagrant sur la figure 3.5, lorsque l'on compare SVM-Margin et SVM-ATU : dans cet exemple, les écarts entre les distributions finales des classes sont plus importants pour Margin que ATU. D'autre part, la lettre «u» par exemple est parmi les classes les plus représentées dans la stratégie Margin alors qu'elle est parmi les classes les moins représentées dans ATU.
- Pour la stratégie Margin, et pour un même participant, les évolutions des distributions varient selon le modèle (cf. par exemple la figure 3.5 et les cas SVM-Margin et KNN-Margin).
- Pour les stratégies Margin ou ATU et pour un même modèle, les évolutions des distributions varient selon le participant (cf. par exemple le cas KNN-Margin des figures 3.5 et 3.6).

### 3.3 Discussion

Dans cette configuration «sans l'humain dans la boucle» d'apprentissage, les résultats montrent que les stratégies Margin et ATU sont plus performantes pour une tâche de classification de gestes que la stratégie Random (contrôle), quel que soit le modèle d'apprentissage utilisé. Dans tout les cas, Margin est celle qui donne les meilleures performances. Cependant, les performances sont davantage dépendantes des modèles que des stratégies. Par exemple, la configuration SVM-Random (moins bonne stratégie pour SVM), donne un meilleur score final que les meilleures stratégies des autres modèles (KNN-Margin, RF-Margin ou NB-Margin). Les distributions des classes dans  $\mathcal{L}$  peuvent difficilement expliquer ces différences de performance entre les stratégies puisqu'elles semblent dépendre de plusieurs facteurs:

- De la stratégie d'apprentissage actif
- Du modèle (pour Margin seulement)
- De la base de données, et du participant ayant exécuté les gestes dans le cadre de cette expérience (pour ATU et Margin seulement).

Cependant, on observe que la stratégie Margin est la plus performante et donne également des distributions finales des classes dans  $\mathcal{L}$  les plus déséquilibrées. On peut émettre l'hypothèse que la stratégie Margin, en proposant des requêtes basées sur l'incertitude du modèle, corrige le modèle en sur-représentant les classes qui demandent plus d'exemple que les autres pour être reconnues correctement.

Il est important de remarquer que les stratégies non-agnostiques comme Margin, sont moins fiables en début d'apprentissage car, étant mal entraînées, leur estimation des probabilités à posteriori seront plus mauvaises qu'en fin d'entraînement. Ainsi, les requêtes seront moins pertinentes au début de l'apprentissage actif. Cependant, elles

engendreront moins de progression en fin d'apprentissage puisque le modèle sera déjà bien entraîné et ses performances de classification tendront vers une valeur limite.

Pour la seconde expérience incluant un «humain dans la boucle», nous avons choisi de garder le modèle SVM avec les mêmes stratégies présentées ici (Random, Margin et ATU). Notre choix s'est fondé sur le modèle donnant les meilleures performances en fin d'apprentissage. Cependant, il serait tout aussi intéressant de considérer des modèles avec une plus faible performance finale mais une plus grande progression (NB) ou encore des modèles avec une plus faible progression (KNN et RF).

Un autre critère de choix possible est la fiabilité des probabilités à posteriori émises par les modèles avec peu d'exemples.

## Chapitre 4

# Seconde Étude : Apprentissage Actif Interactif de gestes de la main

Précédemment, nous avons étudié des modèles d'apprentissage couplés avec des stratégies d'apprentissage actif, sur un ensemble de données gestuelles, «sans l'humain dans la boucle d'apprentissage». A présent, nous cherchons à évaluer l'influence de placer «l'humain dans la boucle» de l'apprentissage. Comme nous l'avons mentionné dans l'introduction et l'état de l'art, l'apprentissage machine interactif introduit une nouvelle rétro-action : l'humain peut adapter ses choix et ses exemples en fonction de sa perception du système. Dans l'étude précédente, la base de données de geste est fixe et l'apprentissage n'influence pas la qualité des gestes.

Placer «l'humain dans la boucle» d'apprentissage, complexifie le problème mais offre aussi la possibilité de s'intéresser à la compréhension et l'adaptation de l'humain au système, en plus d'étudier des critères objectifs comme la performance du système dans la tâche de classification.

Rappelons que nous nous sommes intéressés aux questions de recherches suivantes :

- Quelles sont les différences entre un système d'apprentissage actif sans agent humain <sup>1</sup> et avec agent humain, au niveau des performances objectives?
- Quelle est la compréhension des participants des limites et de la confusion du système?
- Quelles sont les adaptations des participants aux retours d'information du système sur ses capacités de classification?
- Comment les stratégies automatiques d'apprentissage actif se comportent-elles en présence d'un agent humain? Est-ce que les requêtes du système d'apprentissage actif ont du sens pour l'humain?

Comme dans l'expérience précédente, l'étude est un problème de classification de gestes où la tâche est bien définie : entraîner le système à reconnaître des gestes.

Nous commencerons par présenter notre méthode à travers le protocole expérimental, puis nous présenterons les résultats et discuterons des problématiques soulevées ci-dessus.

### 4.1 Méthode

Dans cette section, nous présenterons le dispositif préparé pour l'expérience et le protocole.

---

<sup>1</sup>cf. l'étude précédente (chapitre 3)

### 4.1.1 Participants

L'expérience a été réalisée sur 12 participants âgés en moyenne de 25.3 ans (écart-type = 2.8 ans). On compte parmi ces participants 75% d'hommes et 25% de femmes. Tous sont droitiers. Aucun participant n'a de troubles de la vision (sans compter les personnes possédant un appareil de correction visuelle) ou de troubles moteurs ou cognitifs reconnus. 92% d'entre eux ont déjà utilisé des dispositifs de captation de mouvement pour des jeux vidéos. 75% des participants ont une activité liée à l'informatique.

### 4.1.2 Apparatus

#### Dispositif matériel et logiciel

**Matériel :** Le dispositif matériel est identique à celui présenté à la section 3.1.1.

**Logiciel :** Le routage des données se fait par le biais d'un serveur<sup>2</sup>. Les données issues des capteurs du téléphone sont transmises lorsqu'il est connecté au serveur en tant que client (par le navigateur du téléphone). Ce dernier se charge de découper les gestes quand le participant appuie sur le clavier. Puis le serveur retransmet ces données au programme d'apprentissage machine<sup>3</sup>. Un autre programme est chargé d'enregistrer et de lire les vidéos associées aux gestes effectués<sup>4</sup>. Ces vidéos seront utilisées comme retour d'information durant l'expérience. La communication entre le serveur et le programme d'apprentissage machine et de gestion des vidéos se fait via le format OSC<sup>5</sup> et le protocole UDP<sup>6</sup>. Les données du programme d'apprentissage machine (prédictions) reçues par le serveur sont transmises par websocket au navigateur avant d'être affichées à l'écran. Le routage des données est schématisé sur la figure 4.1.

Pour le modèle d'apprentissage machine, on utilise une Machine à Vecteurs de Support à noyau linéaire puisque c'est le classifieur qui, couplé avec la stratégie d'apprentissage actif Margin, a donné le meilleur taux de prédiction correcte lors de la première étude (cf. 3.4).

Les stratégies utilisées sont les mêmes que dans la première étude : Random (témoins), Margin (stratégie non-agnostique) et ATU (stratégie agnostique) (cf 2.1.3 pour la définition des stratégies).

#### Données gestuelles collectées

Les données collectées sont les mêmes que celles de l'expérience 1 (cf. section 3.1.2).

### 4.1.3 Procédure

Dans cette partie, on présente la structure ainsi que le déroulement des différentes phases de l'expérience.

Le design de l'expérience est «intra-participant» et on a un seul facteur, la stratégie d'apprentissage. L'expérience est composée de trois blocs où seule la stratégie d'apprentissage

<sup>2</sup>Programmé en NodeJS et utilisant les bibliothèques `mano-js` et `waves-lfo` (développés par Benjamin Matuszewski à l'IRCAM) pour le routage des flux de données

<sup>3</sup>Programmé en `Python`, et utilisant la bibliothèque `scikit-learn`

<sup>4</sup>Programmé en `Max MSP`

<sup>5</sup>Open Sound Control

<sup>6</sup>User Datagram Protocol

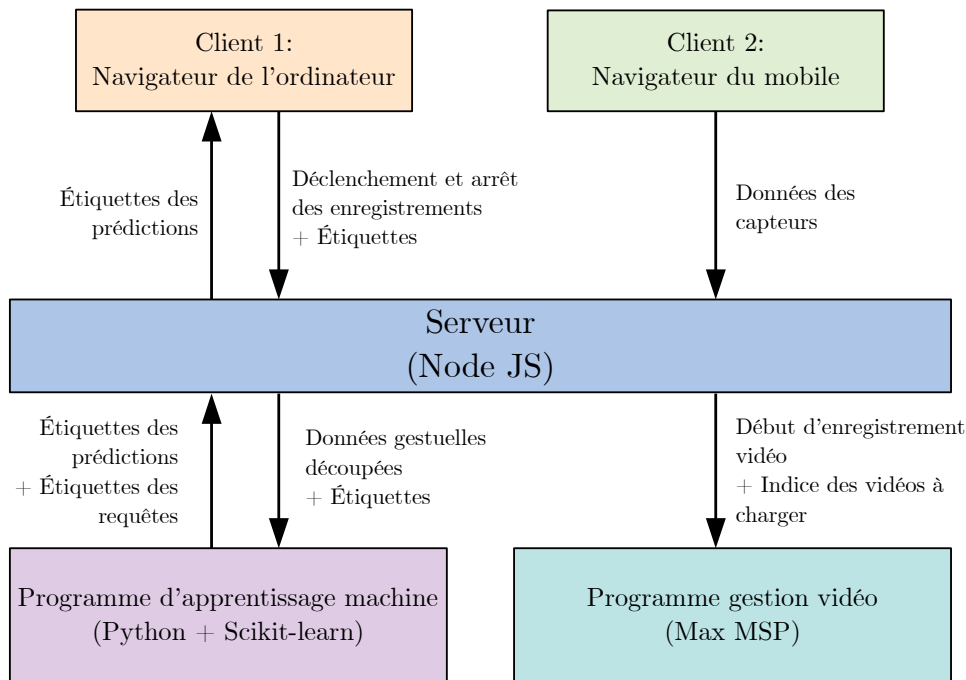



FIG 4.1: Schéma du routage des données de la seconde étude.



3 passes :

- Changement de stratégie d'apprentissage actif
- Classifieur et base de donnée réinitialisés

FIG 4.2: Schéma du déroulement de l'expérience.

machine change. L'ordre des stratégies est contre-balançé sur le nombre de participants. Dans un bloc, on différencie plusieurs phases:

**Instructions :** Cette phase n'apparaît qu'une fois au début de l'expérience. Elle est réalisée à l'oral, en anglais ou en français selon la préférence du participant. Les consignes données au participant sont:

- La tâche est d'entraîner le système à reconnaître des gestes parmi un vocabulaire de 5 gestes.
- Le vocabulaire de geste sont 5 lettres latines - z, m, k, u et p<sup>7</sup> - qui doivent être dessinées en l'air devant soi. Il est précisé que les lettres doivent être écrites de manière personnelle

<sup>7</sup>Les lettres choisies sont les mêmes que celle de l'étude 1, cf 3

mais en lettre cursive.

- Pour enregistrer un geste, il est demandé de maintenir enfoncé un bouton du clavier marqué en rouge. Lorsque le bouton est relâché, l'enregistrement est interrompu.
- On indique le nombre d'itérations pour chaque phase.

De plus, on demande au participant de remplir un formulaire sur son profil afin de recueillir des données démographiques, présentées en 4.1.1.

**Phase d'essai :** Cette phase est identique à la phase d'initialisation sauf que les gestes ne sont pas enregistrés ou utilisés pour l'entraînement. Elle permet au participant de se familiariser avec l'interface. Elle n'est réalisée que pour le premier bloc.

**Phase d'initialisation :** Le système montre les lettres à réaliser en l'affichant au centre de l'écran. Il est demandé au participant de réaliser le geste correspondant à la lettre qui s'affiche. Chaque lettre est demandée 2 fois (10 gestes), dans un ordre aléatoire. A la fin de cette phase, le classifieur est entraîné avec ces exemples de 10 gestes.

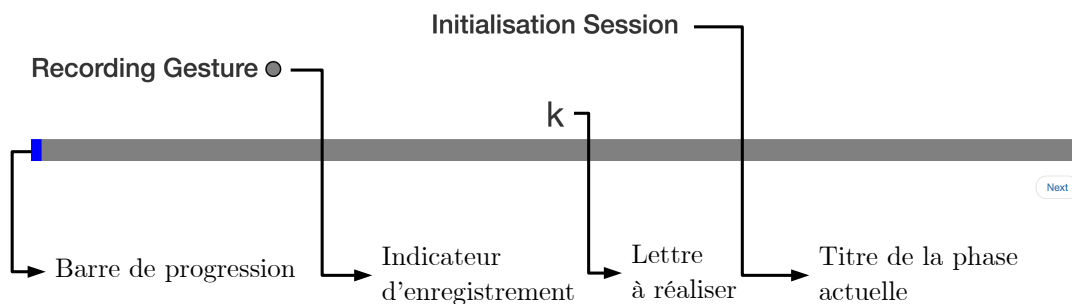


FIG 4.3: Interface lors de la phase d'initialisation

**Phase de performance :** Le système attend cette fois qu'un geste soit enregistré pour donner une prédiction. La lettre prédite s'affiche en bleu au centre de l'écran, pendant 1 seconde avant de disparaître. Le participant a 20 essais et peut choisir la lettre qu'il veut. L'ordre et le nombre des lettres réalisées sont choisis par le participant<sup>8</sup>. On demande également au participant de placer un jeton sur la lettre qu'il souhaite réaliser (les lettres sont affichées sur la table). Les gestes étant enregistrés par la caméra de l'ordinateur, on pourra ensuite accéder à l'intention du participant et calculer les performances de la classification.

Chaque geste est annoté à la main, ultérieurement à l'expérience, grâce à la position du jeton sur l'enregistrement vidéo.

Les données des capteurs et la vidéo des gestes enregistrées pendant cette phase font alors partie de l'ensemble  $\mathcal{U}$  des instances non-étiquetées. Ces instances seront stockées jusqu'à la fin du bloc. C'est dans cet ensemble que l'algorithme d'apprentissage machine choisit les gestes à faire étiqueter par le participant, lors de l'étape d'enseignement.

<sup>8</sup>On l'informe juste qu'il est préférable d'essayer chaque lettre afin de pouvoir répondre au questionnaire de la phase suivante.

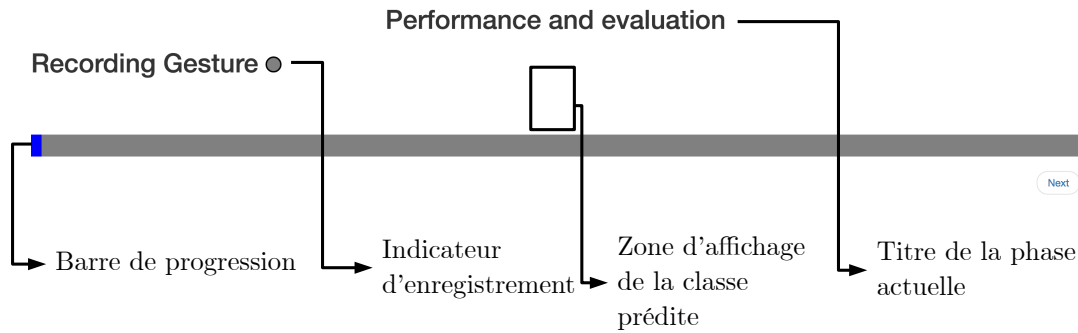


FIG 4.4: Interface lors de la phase de performance




FIG 4.5: Dispositif d'enregistrement des gestes lors de la phase de performance

**Phase d'évaluation :** À la fin de la phase de performance, on demande au participant de remplir une fiche d'évaluation subjective sur la capacité de l'algorithme à reconnaître les gestes. Le questionnaire pose la question suivante : «Est-ce que l'algorithme a reconnu correctement vos gestes?». Pour chaque lettre, l'évaluation contient 7 cases (une seule à cocher) allant de «jamais» à «toujours». La fiche donnée aux participants est donnée en annexe A.1. On précise que l'évaluation est subjective et qu'il ne s'agit pas de juger les capacités de mémoire du participant.

**Phase d'entraînement :** Le système présente au participant une vidéo d'un geste précédemment enregistré dans les phases de performance. Le choix de cette vidéo est aléatoire pour la stratégie Random, et actif pour les deux autres stratégies<sup>9</sup>. Le participant doit cocher (avec la souris) la lettre qu'il pense reconnaître sur la vidéo. Une fois l'étiquette apposée, le geste est transféré de l'ensemble des gestes non-étiquetés  $\mathcal{U}$  à l'ensemble d'entraînement  $\mathcal{L}$ . Le classifieur est alors entraîné sur les instances de  $\mathcal{L}$  issues de la phase d'initialisation et des requêtes de la phase d'entraînement. Après chaque requête, le classifieur est entraîné de nouveau, puis le système choisit de nouveau un geste à étiqueter. Durant cette phase,

<sup>9</sup>L'algorithme d'apprentissage machine ne prend en compte que les données gestuelles issues du smart-phone et non pas les données vidéo de la caméra.



5 gestes sont choisis et le modèle est réentraîné 5 fois. Il est important de réentraîner le modèle à chaque requête puisque la stratégie Margin repose sur les probabilités à postériori du modèle courant. L'ensemble d'entraînement augmente donc de 5 instances à la fin de la phase.

**Itération :** Après la phase d'entraînement, on itère 4 fois depuis la phase de performance jusqu'à l'entraînement. Ces itérations sont représentées sur la figure 4.2.

**Discussion finale :** Après avoir fait les 3 blocs, le participant est invité à discuter sur son expérience. la discussion est enregistrée et les commentaires libres sont collectés. Durant cette discussion, on demande aux participants s'il a identifié des différences entre les trois blocs. Puis, on demande s'il a identifié une logique dans les requêtes de l'algorithme ou dans la qualité de la reconnaissance durant la phase de performance. L'expérience se termine après cette discussion.

## 4.2 Résultats

Nous présentons dans cette partie les résultats des analyses des données de l'expérience. Les analyses se focalisent sur les questions de recherche exposées à la section 4. Dans les sections suivantes, on expose les résultats relatifs aux performances objectives du système, aux performances perçues, au comportement des stratégies d'apprentissage actif, à l'adaptation des participants au système et l'adaptation du système aux individus.

### 4.2.1 Performances objectives de classification

Tout d'abord, on cherche à quantifier les performances objectives de l'algorithme selon les stratégies d'apprentissage actif. On calcule le taux de prédiction correcte pour les quatre phases de performance. Il s'agit du nombre de prédictions correctes sur le nombre total de prédictions (correctes et incorrectes) (cf. equation 3.1).

On rappelle que pour accéder aux vraies étiquettes, on demande au participant de placer un jeton sur la lettre qu'il effectue. Les lettres sont affichées sur la table et les enregistrements vidéos permettent d'accéder aux étiquettes après l'expérience (cf. figure 4.5). Chaque geste est annoté «à la main», en visionnant les vidéos.

Le score calculé avec l'équation 3.1 est moyenné entre les participants, pour chaque phase de performance. Cette moyenne est tracée sur la figure 4.6, pour les trois stratégies d'apprentissage actif. L'écart-type est représenté par une bande autour de la valeur moyenne (de même couleur).

On remarque qu'à la première itération, il n'y a aucune différence significative entre les différentes stratégies ( $p_{value} = 0.9284$ ,  $F_{critical} = 3.403$  pour  $\alpha = 0.05$ ). Cela confirme l'absence de biais dans la configuration initiale (avant les requêtes).

Même si la stratégie Margin a une moyenne plus élevée que les autres stratégies pour les 3 dernières itérations, elle n'est significativement différente que pour la seconde ( $p_{value} = 0.0197$ ). Elle est également proche d'être significativement différente des deux autres stratégies pour la 4ème itération ( $p_{value} = 0.05620 > \alpha$ ). La stratégie ATU ne diffère pas significativement de la stratégie Random (contrôle).

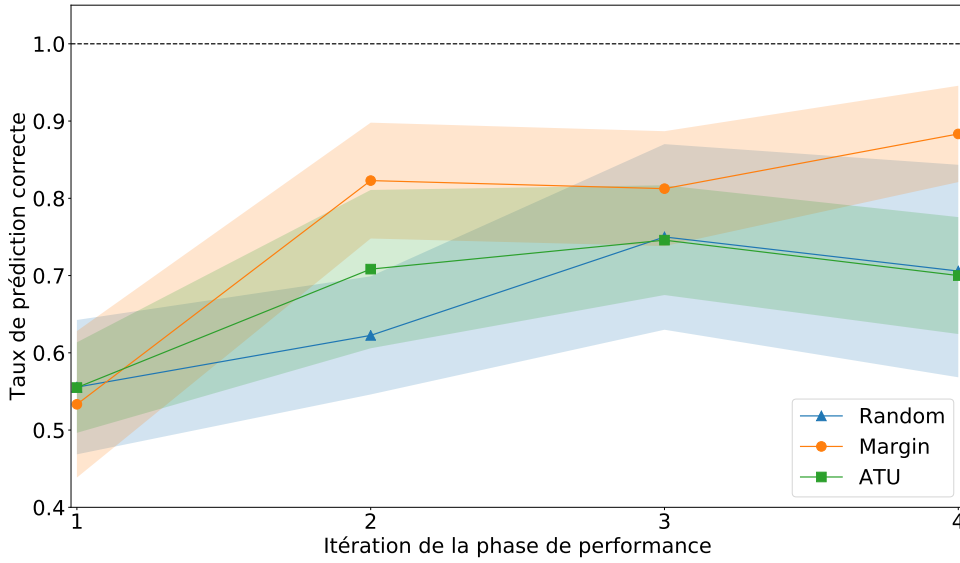


FIG 4.6: Taux de prédiction correcte lors des 4 itérations de la phase de performance de l'expérience, moyennés sur les participants et pour les trois stratégies d'apprentissage actif.

#### 4.2.2 Performances de classification perçues

Dans cette section, on étudie les performances perçues par les participants. Lors de la phase de performance, les participants ont 20 réalisations de gestes pour évaluer la fiabilité du système dans la reconnaissance des classes. On cherche d'abord à évaluer la corrélation entre les évaluations subjectives données par les participants durant la phase d'évaluation avec les performances objectives calculées à partir des prédictions de la phase de performance.

D'une part, on calcule la précision par classe, c'est à dire le nombre de fois que le geste est correctement classifié divisé par le nombre de fois que la classe est demandée. Autrement dit, cela répond à la question : Combien d'éléments sélectionnés (gestes d'une classe donnée), ont correctement été prédits? La précision pour une classe  $i$  s'écrit:

$$Précision_i = \frac{Nb_{Vrais\ positifs\ pour\ la\ classe\ i}}{Nb_{Éléments\ dans\ la\ classe\ i}} \quad (4.1)$$

D'autre part, on normalise entre 0 et 1 les notes subjectives des participants données pour chaque classe à la fin de la phase de performance.

Les évaluations et la précision sur les classes peuvent être vues comme des variables aléatoire sur lesquelles on calcule une corrélation de Pearson. La corrélation de Pearson est une corrélation linéaire traduisant l'intensité de la liaison qui peut exister entre ces deux variables. Le coefficient de corrélation entre deux variables aléatoires réelles  $X$  et  $Y$  ayant chacune une variance finie, noté  $Cor(X, Y)$ , est défini par:

$$Cor(X, Y) = \frac{Cov(X, Y)}{\sigma_X \sigma_Y} \quad (4.2)$$

où  $Cov(X, Y)$  désigne la covariance des variables  $X$  et  $Y$  et  $\sigma_X$  et  $\sigma_Y$  leurs écarts types.

Dans certains cas, les évaluations sont identiques pour chaque classe. Dans ce cas, (si l'une des distributions est constante), la corrélation n'est pas définie puisque l'écart-type de l'une des variables vaut 0. On choisit dans ces cas, de retirer la valeur de la statistique puisque la corrélation n'est alors pas définie. Ce cas de figure est plus probable dans les deux dernières itérations, lorsque le modèle est bien entraîné et donne de bonnes performances de classification. Cela représente 9 cas sur 144 soit 6.25 % des cas.

On moyenne le coefficient de corrélation sur les participants et on observe cette moyenne (et son écart-type) en fonction des 4 itérations et pour les 3 stratégies d'apprentissage actif. La corrélation est toujours positive, et proche de 1. Il n'y a aucune différence significative entre les stratégies et la moyenne globale est d'environ 0.86. Ces résultats permettent de vérifier que l'évaluation des participants reste cohérente avec la performance objective du système lors de la phase de performance.

### 4.2.3 Comportement des stratégies d'apprentissage actif

Dans cette partie, on expose les résultats relatifs au comportement de l'apprentissage actif, et plus particulièrement le choix des requêtes.

#### Lien entre les performances perçues et le choix des requêtes

Dans cette partie, on s'intéresse à la corrélation entre les requêtes des stratégies d'apprentissage actif et les performances perçues par le participant (via les notes données durant la phase d'évaluation). De manière similaire à la partie 4.2.2, on calcule une corrélation de Pearson entre deux variables aléatoires:

- La première est les évaluations subjectives des participants pour chaque classe, normalisées entre 0 et 1.
- La seconde est la proportion de chaque classe dans les requêtes de la phase d'entraînement. On calcule simplement le nombre d'apparitions d'une classe dans les requêtes divisé par le nombre total de requêtes de la phase en cours (5 requêtes).

Le score ainsi obtenu pour chaque participant, stratégie et itération, reflète si l'incertitude perçue par les participants a un lien avec les classes sélectionnées par le système et si cela dépend de la stratégie d'apprentissage actif.

Le score de corrélation sera proche de -1 si les classes perçues comme les plus confuses sont majoritairement demandées lors des requêtes de la phase d'enseignement, et vice versa<sup>10</sup>. Le score de corrélation sera proche de 1 si les classes perçues comme les moins confuses sont majoritairement demandées lors des requêtes de la phase d'enseignement, et vice versa<sup>11</sup>. Les scores proches de 0 ne démontrent aucun lien particulier entre les deux variables.

On trace les scores de corrélation moyennés sur les participants, en fonction des itérations et pour chaque stratégie d'apprentissage actif sur la figure 4.7.

<sup>10</sup>Si les classes perçues comme les moins confuses sont moins demandées lors des requêtes de la phase d'enseignement.

<sup>11</sup>Si les classes perçues comme les plus confuses sont majoritairement demandées lors des requêtes de la phase d'enseignement.

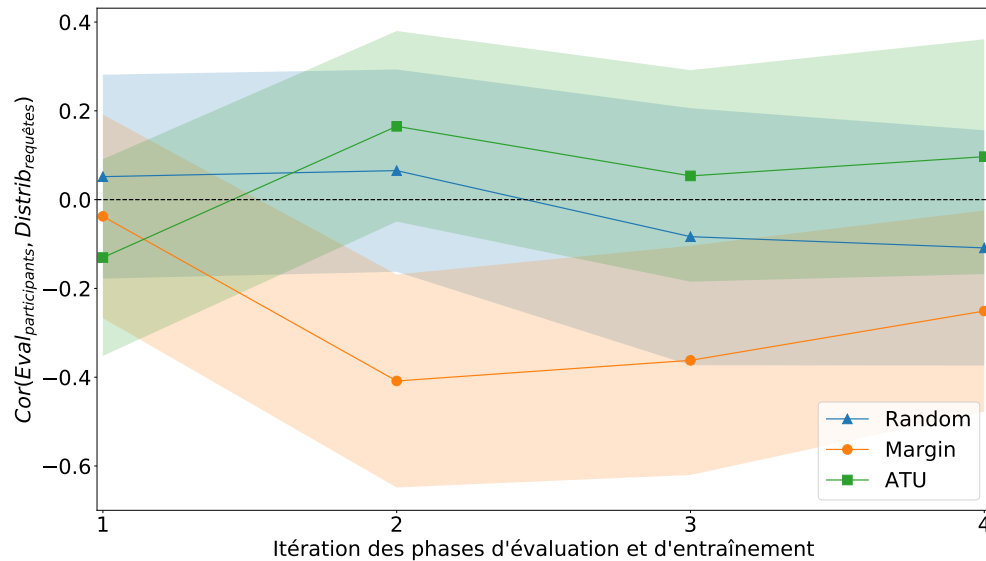


FIG 4.7: Corrélation de Pearson entre les évaluations subjectives des participants et la distribution des classes demandées par l'algorithme lors de la phase d'enseignement, en fonction des 4 itérations et moyennées sur les participants, pour 3 stratégies d'apprentissage actif (Random, Margin et ATU)

On remarque que les corrélations sur les itérations pour les stratégies Random et ATU restent proches de 0 et ne sont pas significativement différentes. Seule la stratégie Margin lors de l'itération est significativement différente des deux autres stratégies ( $p_{value} = 0.0276$ ,  $F_{critical} = 3.328$  pour  $\alpha = 0.05$ ). De plus, la corrélation négative est cohérente avec la définition de la stratégie Margin, qui repose sur la sélection des instances les plus incertaines selon le modèle : il y a davantage de requêtes pour les classes évaluées avec un score plus bas par les participants.

Le comportement de la stratégie ATU ne semble pas corrélé avec la confusion perçue par les participants. Cependant, il a été mis en évidence que la stratégie ATU n'améliore pas significativement les performances objectives du système de reconnaissance (cf figure 4.2.1). On peut émettre l'hypothèse qu'une faible corrélation entre les requêtes et les classes perçues comme moins bien reconnues entraîne de faibles performances objectives. Cette supposition sera discutée ultérieurement (cf. section 4.3).

Comme dans la partie 4.2.2, les évaluations subjectives ou les requêtes donnent parfois des valeurs constantes. La corrélation de Pearson n'est alors pas définie puisque la variance de l'une des deux variables est nulle. Dans ce cas, la corrélation est retirée des statistiques (c'est le cas dans la figure 4.7).

Afin de vérifier les résultats précédents (figure 4.7), on calcule une corrélation de Pearson sur les mêmes variables<sup>12</sup> mais concaténées sur les itérations. On ne calcule plus une corrélation par itération, par sujet et par stratégie, avec deux variables de longueur 5 (le nombre de lettre). On calcule à présent une corrélation par sujet et par stratégie avec deux vecteurs de longueur 20 (5 classes concaténées sur 4 itérations). Dans ce cas, on exclue la possibilité d'avoir des variables

<sup>12</sup>Les évaluations subjectives des participants pour chaque classe et la distribution du nombre de requêtes sur les classes.

constantes. La corrélation est plus fiable car elle est réalisée sur des vecteurs plus grands, mais on perd l'information de l'évolution de cette corrélation au cours de l'expérience. Enfin, on moyenne les corrélations sur les participants et on trace ce score de corrélation moyennée pour les 3 stratégies sur la figure 4.8.

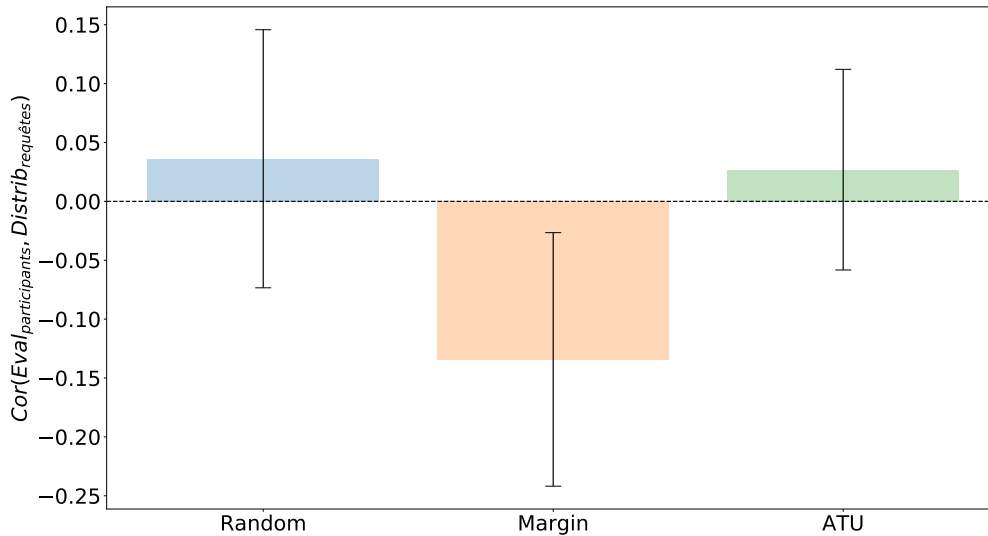


FIG 4.8: Corrélation de Pearson entre les évaluations subjectives et la distribution des classes demandées par l'algorithme lors de la phase d'enseignement, concaténées sur les 4 itérations et moyennées sur les participants, pour 3 stratégies d'apprentissage actif (Random, Margin et ATU)

On observe que les stratégies Random et ATU donnent de faibles corrélations positives tandis que la stratégie Margin donne une corrélation négative. En faisant un test ANOVA<sup>13</sup> avec  $\alpha = 0.05$ , on obtient que les stratégies ne sont pas significativement différentes ( $p_{values} = 0.1014$ ). Bien que les stratégies ne soient pas significativement différentes, ces résultats ont du sens avec la définition de la stratégie Margin, qui en théorie, demande majoritairement les classes les plus ambiguës<sup>14</sup>.

### Évolution de l'ensemble d'entraînement

On s'intéresse dans un premier temps à la distribution des classes dans l'ensemble d'entraînement  $\mathcal{L}$  au cours de l'expérience. Sur la figure 4.9, on trace le nombre moyen d'instances par classe en fonction du nombre de requêtes, pour les 3 stratégies d'apprentissage actif.

On observe que la stratégie ATU a la plus grande variance dans la distribution des classes demandées, en favorisant les requêtes de deux classes, u (rouge) et m (orange). La stratégie Random semble bien ne favoriser aucune classe tandis que la stratégie Margin favorise légèrement la lettre k.

<sup>13</sup>ANalysis Of VAriance

<sup>14</sup>Dont la marge entre les deux plus grandes probabilités à posteriori est la plus faible.

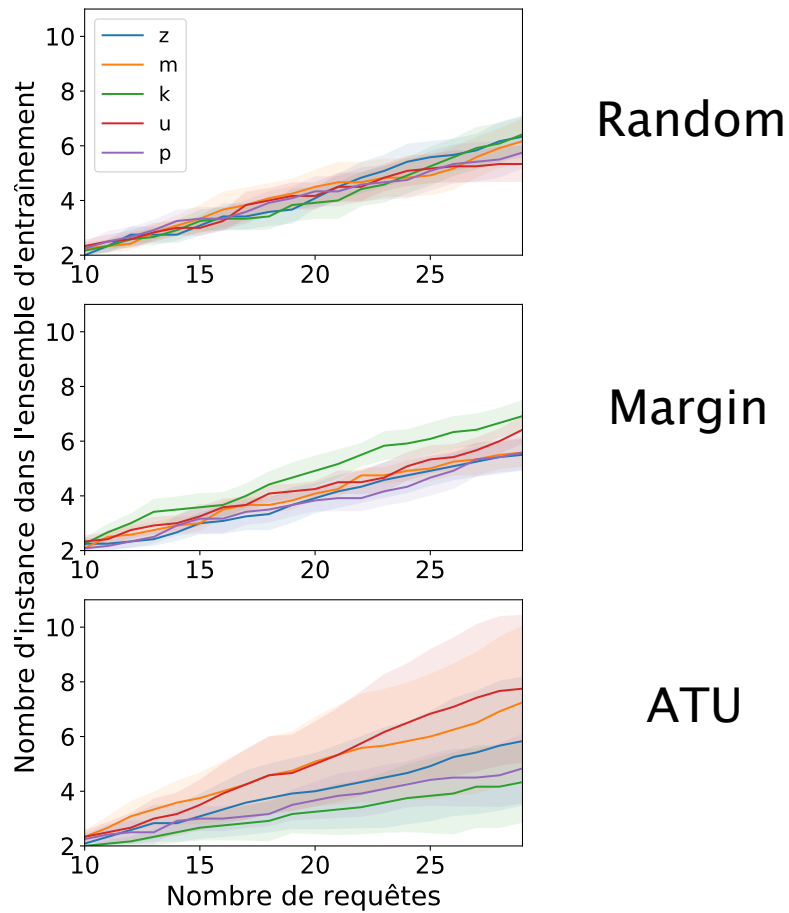


FIG 4.9: Distributions des classes (lettres) de l'ensemble d'entraînement au cours de l'expérience, pour les trois stratégies (Random, Margin et ATU) et pour 5 gestes du vocabulaire, moyennées parmi les participants.

On rappelle que la stratégie Random ne sélectionne pas les classes de manière équiprobable. Le choix dépend de la distribution des classes dans l'ensemble  $\mathcal{L}$ . Cette distribution découle des réalisations du sujet dans la phase de performance, qui n'est pas contraint d'effectuer le même nombre d'exemples par classe (cf. 4.2.3).

#### Lien entre la confusion du système et le choix des requêtes

Lorsqu'un geste n'est pas reconnu dans la phase de performance, deux comportements opposés ont été observés:

1. Soit les prédictions incorrectes pour une classe donnée donnent systématiquement la même prédiction erronée.
2. Soit les prédictions incorrectes pour une classe donnée sont réparties sur les autres classes.

Le premier cas de figure reflète une situation où le modèle prédit incorrectement avec certitude tandis que le second cas de figure reflète une situation où le modèle est incertain sur la prédiction. On s'intéresse à corrélérer ces deux situations avec les classes demandées dans la phase d'enseignement. On cherche donc à lier la confusion du système avec la distribution des requêtes sur les classes.

Pour cette analyse, on commence par calculer la matrice de confusion à partir des prédictions de la phase de performance, pour chaque participant, stratégie et itération. Chaque colonne de la matrice représente le nombre d'occurrences d'une classe estimée, tandis que chaque ligne représente le nombre d'occurrences d'une classe réelle (ou de référence). On calcule l'écart-type sur les lignes de matrices de confusion dont on a supprimé préalablement les éléments diagonaux. La diagonale représente le taux où la classe en question a été correctement prédite. L'écart-type ainsi calculé nous donne une estimation du comportement des prédictions dans le cas où il classifie incorrectement:

- Si les prédictions incorrectes donnent systématiquement la même lettre, on aura une valeur élevée.
- A l'inverse, si les prédictions incorrectes sont uniformément réparties sur les autres classes, la valeur sera nulle.

On calcule ce score pour chaque lettre. Un score bas signifie des probabilités équiprobables lors de la prédiction d'une classe. D'autre part on calcule le nombre de requêtes d'une classe sur le nombre total de requêtes, pour chaque classe. De la même manière qu'à la partie 4.2.3, on concatène les valeurs obtenues pour chaque itération. On obtient deux vecteurs de taille 20 (5 classes  $\times$  4 itérations), pour chaque participant et pour chaque stratégie. Puis, on calcule la corrélation de Pearson de ces deux vecteurs<sup>15</sup>. Sur la figure 4.10, on trace la moyenne de ce score de corrélation sur les participants, en fonction des 4 itérations et pour les 3 stratégies d'apprentissage actif.

Seule la stratégie Margin obtient une valeur de corrélation négative. Cela signifie que pour cette stratégie, les classes dont les prédictions incorrectes sont uniformément réparties sur les autres classes seront davantage demandées dans les requêtes. De même les classes dont les prédictions incorrectes donnent majoritairement la même lettre seront moins demandées dans les requêtes.

#### 4.2.4 Adaptation des participants

On s'intéresse à présent aux adaptations du participant au système. Étant donné que le participant est libre du choix des gestes dans la phase de performance, son adaptation pourrait s'exprimer dans le choix des gestes durant cette phase, en choisissant davantage une classe qu'une autre.

On décide de corrélérer la distribution des classes choisies dans la phase performance avec les évaluations subjectives (normalisés entre 0 et 1). La démarche est identique à celle présentée à la partie 4.2.3, sauf que l'on utilise la distribution sur les classes des gestes choisis par l'humain dans la phase de performance au lieu de la distribution sur les classes des gestes

<sup>15</sup>Ecart-types de la matrice de confusion et distribution des classes lors des requêtes de l'algorithme, concaténés sur les itérations.

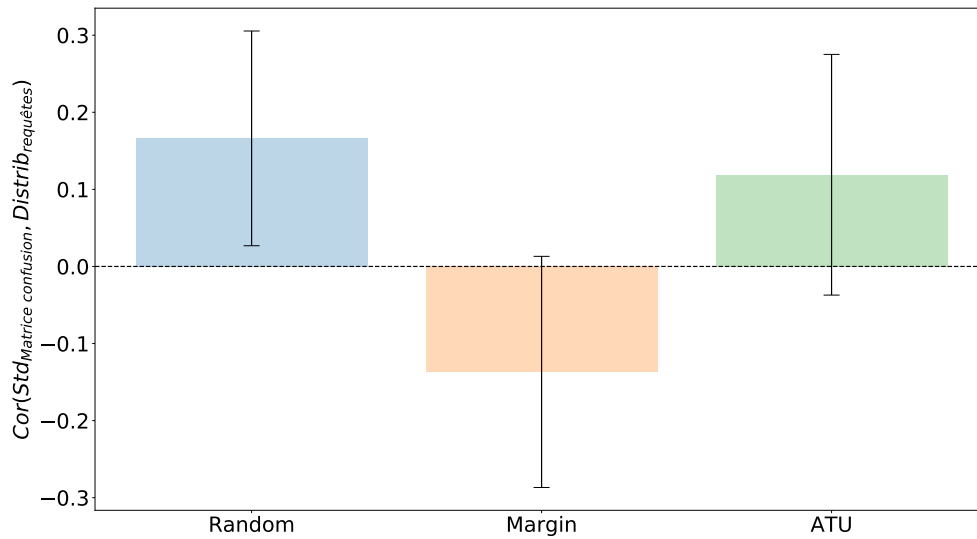


FIG 4.10: Corrélation de Pearson entre l'écart-type de la matrice de confusion et la distribution des classes demandées par l'algorithme lors de la phase d'enseignement, concaténées sur les 4 itérations et moyennées sur les participants, pour 3 stratégies d'apprentissage actif (Random, Margin et ATU)

choisis par l'algorithme dans la phase d'entraînement.

De la même manière qu'à la partie précédente, les distributions sur les classes des gestes choisis dans la phase de performance et les évaluations subjectives des participants sont concaténées sur les itérations.

Sur la figure 4.11, on trace la corrélation de Pearson de ces deux variables, moyennées sur les participants et pour les 3 stratégies d'apprentissage actif.

On observe que, pour les trois stratégies, la corrélation est négative. Cela signifie que dans tous les cas, les classes perçues comme les moins reconnues vont être majoritairement choisies dans la phase de performance, et vice versa<sup>16</sup>.

On obtient une corrélation négative plus importante pour la stratégie Random, puis ATU et enfin Margin. Cette observation est surprenante puisqu'à priori, l'adaptation du choix des gestes avec la performance perçue du système est indépendante de la stratégie. D'après le test ANOVA, les trois stratégies ne sont pas significativement différentes avec  $\alpha = 0.05$ .

#### 4.2.5 Adaptation du système aux individualités

Jusqu'à présent nous avons observé des comportements moyennés sur les participants. Nous savons de l'état de l'art que l'amélioration des performances d'apprentissage du système dans une configuration d'apprentissage actif est dépendant de plusieurs facteurs : le modèle d'apprentissage machine, des caractéristiques de la base donnée (type de données, nombre de

<sup>16</sup>Les classes les mieux reconnues vont être minoritairement choisies dans la phase de performance.






FIG 4.11: Corrélation de Pearson entre les évaluations subjectives et la distribution des classes de gestes choisies par le participant lors de la phase de performance, concaténées sur les 4 itérations et moyennées sur les participants, pour 3 stratégies d'apprentissage actif (Random, Margin et ATU)

classe etc...) et de la qualité de l'«oracle»<sup>17</sup>.

Cette seconde étude se place dans une configuration fixée du modèle (SVM) et de la base de données (gestes). On s'intéresse dans cette partie à l'influence de la variabilité de l'agent humain sur les performances objectives du classifieur (cf. section 4.2.1), sur la corrélation entre les évaluations subjectives des participants sur les classes avec la distribution des classes dans les requêtes de la phase d'enseignement (cf. figure 4.2.3) et sur le choix des requêtes en fonction des différentes stratégies (cf. figure 4.2.3). Les critères calculés sont les mêmes qu'aux parties 4.2.1, 4.2.3 et 4.2.3 sauf qu'on les calcule pour un sous-ensemble de 5 participants. On trace :

- Le taux de prédiction correcte (figure 4.12.a),
- La corrélation entre les évaluations subjectives des participants et la distribution des classes dans les requêtes du système de la phase d'enseignement (figure 4.12.b).
- La distribution des classes dans l'ensemble d'entraînement  $\mathcal{L}$  (figure 4.13).

On remarque que les performances pour les trois stratégies diffèrent pour chaque participant. Par exemple, pour le participant 2, les trois stratégies donnent des performances similaires et la stratégie Margin est la plus faible. À l'inverse, pour le participant 3, les performances entre les trois stratégies sont très différentes et la stratégie Margin est bien au dessus des deux autres.

Concernant la corrélation entre les évaluations subjectives des participants et la distribution des classes dans les requêtes de la phase d'enseignement, on remarque que la stratégie Margin est toujours négative, bien qu'elle soit proche de 0 pour le participant 3. Le participant 3 est le seul cas où une autre stratégie (ATU) a une corrélation inférieure à la stratégie Margin.

<sup>17</sup>Entité qui annote les requêtes du système. Dans notre cas, il s'agit d'un participant humain.

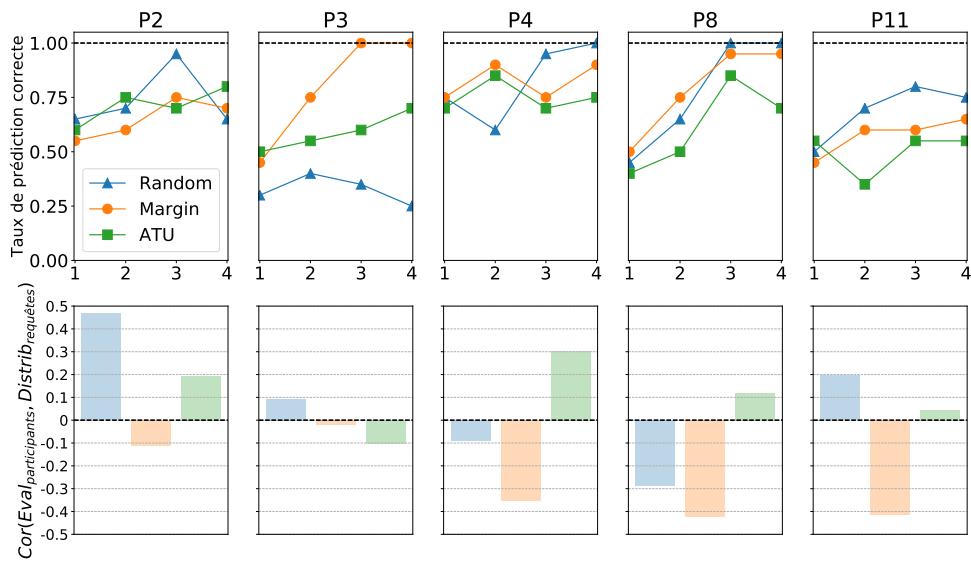


FIG 4.12: Taux de prédiction correcte (ligne du haut) et corrélation entre les évaluations subjectives et les classes demandées dans les requêtes (ligne du bas) lors des 4 itérations de la phase de «Performance» de l'expérience, pour 5 participants isolés et pour les trois stratégies d'apprentissage actif (Random, Margin et ATU)




FIG 4.13: Distribution des classes (lettres) de l'ensemble d'entraînement au cours de l'expérience, pour les trois stratégies (Random, Margin et ATU) et pour 5 gestes du vocabulaire, pour 5 participants isolés.

Enfin, les distributions des classes dans l'ensemble d'entraînement  $\mathcal{L}$  montrent bien que les stratégies Margin et ATU privilégient certaines classes au dépend des autres. Ce comportement est particulièrement marqué pour la stratégie ATU, qui exclut parfois certaines classes des requêtes. Cependant, les classes prédominantes dans la stratégie ATU changent. Pour

le participant 2, c'est la lettre «m» qui est majoritairement demandée tandis que pour le participant 4, c'est la lettre «u».

## 4.3 Discussion

Dans cette section, on discutera des résultats obtenus dans les deux études aux chapitres 4 et 3.

### 4.3.1 Différences entre l'apprentissage actif «avec et sans un humain dans la boucle».

Si l'on met en regard les figures 4.6 et 3.5 (seulement le premier tracé correspondant au modèle SVM), on peut remarquer que:

Les performances initiales (avant la première requête d'apprentissage actif) sont légèrement supérieures dans le contexte interactif. Cette différence peut être due au fait que les participants des deux études sont différents. De plus il n'y a que 4 participants pour la première étude contre 12 pour la seconde. Pour s'assurer que les scores initiaux sont identiques, il faudrait utiliser les mêmes participants dans les deux expériences.

Les performances finales sont très proches pour la stratégie Margin, mais plus faibles dans le cas interactif pour Random et ATU. Une explication possible de cette différence pourrait être la différence entre les ensembles des instances non-étiquetées  $\mathcal{U}$  entre les deux configurations. Dans le cas non interactif, l'ensemble  $\mathcal{U}$  est grand comparé à  $\mathcal{L}$  (240 échantillons dès la première requête). Dans le cas interactif,  $\mathcal{U}$  s'accroît au cours de l'expérience. Les 20 gestes réalisés dans la phase de performances viennent s'ajouter à l'ensemble  $\mathcal{U}$  à chaque itération. De plus les 5 requêtes par itération font décroître l'ensemble  $\mathcal{U}$ . Les requêtes sont donc faites dans un ensemble réduit de geste compris entre 20 et 45 échantillons pour le cas interactif. Cela a probablement une influence sur les performances des stratégies Margin et ATU puisque le choix réduit dans la configuration interactive devrait engendrer des requêtes moins pertinentes. Cependant, cela n'explique pas la différence de performance dans les dernières itérations pour la stratégie Random.

### 4.3.2 Lien entre les performances objectives et les requêtes.

Dans la configuration interactive, les classes demandées dans les requêtes de la stratégie ATU étaient souvent répétitives. Par exemple, dans la figure 4.13, pour le participant 4, la lettre «u» est présente 18 fois dans  $\mathcal{L}$  à la fin de l'apprentissage alors que les lettres «k» et «m» n'ont jamais été demandés dans les requêtes. Ce déséquilibre entraîne une performance finale plus faible que les autres stratégies Random et Margin pour ce participant. Cependant, la performance finale de cette stratégie pour ce participant est bonne comparée au autres participants. Par exemple, ce score final est équivalent à la meilleure stratégie du participant 11.

Cela montre une influence plus forte de la réalisation personnelle des gestes que celle des requêtes de l'apprentissage actif sur les performances finales.

La figure 4.10 montre que les requêtes de la stratégie Margin sont majoritairement des classes dont les prédictions incorrectes sont également réparties sur les autres classes. Cela confirme la tendance des stratégies non-agnostiques par incertitude à maximiser la certitude

dans les prédictions et non pas maximiser la confiance du modèle dans ses prédictions.

### 4.3.3 Lien entre l'incertitude perçue et les requêtes de l'apprentissage actif.

La figure 4.8 montre que la stratégie Margin sélectionne dans ses requêtes, des instances dont les classes sont celles perçues comme les moins bien reconnues par les participants. La figure 4.7 confirme ce résultat et précise que la corrélation est faible en début d'apprentissage et diminue à la dernière itération. La forme convexe de la courbe de la figure 4.7 correspondant à la stratégie Margin peut s'expliquer par les observations suivantes:

- Comme nous l'avons mentionné dans la partie 3.3, la qualité de l'estimation des probabilités à posteriori dépend de l'entraînement du modèle. Le modèle étant peu entraîné en début d'apprentissage, le choix des requêtes sera moins pertinent.
- En milieu d'apprentissage, la stratégie Margin va sélectionner les instances des classes les moins reconnues. Cela va certainement permettre d'équilibrer la performance du modèle sur les classes.
- En fin d'apprentissage, la stratégie Margin donne des performances plus équilibrées entre les classes. Cela explique la baisse de la corrélation entre les performances perçues et les requêtes. Les évaluations subjectives sont davantage constantes et la valeur de corrélation diminue.

D'après la figure 4.9 et la figure 4.13, on observe des requêtes non uniformes sur les classes pour les stratégies ATU et Margin, avec un déséquilibre entre les classes plus fort pour ATU. Cependant, seul Margin présente une corrélation entre les requêtes et les performances perçues. La stratégie Margin, en plus de proposer des requêtes plus cohérentes vis à vis de la perception des participants, obtient les meilleures performances en moyennes. On peut supposer que la tendance à favoriser les requêtes sur les classes les moins reconnues permet d'obtenir de meilleures performances en moyenne.

Cependant, d'après la figure 4.12, ce comportement n'est pas observable lorsqu'on observe les résultats des participants indépendamment. En effet, les stratégies donnant les corrélations les plus négatives ne sont pas forcément les plus performantes. Une stratégie peut obtenir de bonnes performances de classification quelque soit l'équilibre des classes dans l'ensemble  $\mathcal{L}$ .

### 4.3.4 Adaptation de l'humain à l'incertitude perçue.

La figure 4.11 montre les corrélations entre la distribution des classes choisies dans la phase de performance et les évaluations subjectives sur les classes.

Dans les trois stratégies, la corrélation est négative, ce qui montre que les participants choisissent majoritairement les classes qu'ils perçoivent comme les moins bien reconnues. Ce comportement est une adaptation des participants à l'incertitude perçue. Cela engendre également un déséquilibre des classes dans l'ensemble  $\mathcal{U}$  qui peut avoir une influence sur les autres mesures effectués dans l'expérience 2, notamment pour la stratégie Random qui conserve en moyenne la distribution des classes dans  $\mathcal{U}$ .

Par ailleurs, on observe que la stratégie Margin a une corrélation négative moins importante qu'ATU et que Random. Cela pourrait s'expliquer avec la remarque faite à la section précédente : la stratégie Margin tend à équilibrer les performances entre les classes en demandant majoritairement les classes les moins reconnues (cf. 4.7).

Ainsi, les performances perçues étant plus équilibrées, les participants favorisent moins une

---

classe qu'une autre. Cela explique que la corrélation de la stratégie Margin sur la figure 4.11 soit plus faible que les autres stratégies.

## Chapitre 5

# Conclusion

Ce travail a permis d'explorer l'apprentissage actif sur une tâche de classification, dans un contexte interactif. Les contributions et les perspectives de ce travail sont présentées.

### 5.1 Résumé des contributions

Les principales contributions résumées ici sont à mettre en regard avec les objectifs définis à la section 1:

1. Dans la première étude non interactive, la stratégie Margin a montré de meilleures performances de classification que la stratégie ATU, qui elle-même a de meilleures performances que la stratégie de contrôle Margin.  
Dans un contexte interactif, l'ordre des performances entre les stratégies est conservé même si on observe une baisse des performances finales pour les trois stratégies.
2. Dans un contexte non interactif, les stratégies Margin et ATU favorisent certaines classes dans leurs requêtes. Les classes demandées dans les requêtes dépendent à la fois du modèle et du participant dont provient les données (cf. 3.3).  
Dans un contexte interactif, les stratégies Margin et ATU favorisent aussi certaines classes (les requêtes de la stratégie ATU sont particulièrement répétitives chez certains participants). Les classes favorisées dépendent également du participant. De plus la stratégie Margin favorise les requêtes sur les classes dont les prédictions incorrectes sont équilibrées sur les autres classes. En d'autres termes, les requêtes de Margin ne favorisent pas les classes dont les prédictions incorrectes sont émises avec une grande certitude (l'erreur produit systématiquement la même classe).
3. Les participants perçoivent tous une progression du modèle dans la reconnaissance de leurs gestes. Ils perçoivent également quelles sont les classes les mieux ou les moins bien reconnues.
4. Les participants s'adaptent aux limites du système en favorisant le choix des gestes dont les classes sont les moins bien reconnues par le système durant la phase de performance. Une adaptation au travers de l'exécution des gestes n'a pas été étudiée.
5. En observant les participants individuellement, aucun lien entre le choix des classes dans les requêtes et les performances objectives ne peut être établi. Les performances semblent dépendre davantage de la réalisation personnelle des gestes par le participant que de la stratégie d'apprentissage actif. Seules des tendances moyennées entre les participants montrent l'avantage de la stratégie Margin sur les autres.  
En moyenne, la stratégie Margin choisit des requêtes dont les classes sont celles étant perçues comme les moins bien reconnues. Cela signifie que le comportement de la stratégie Margin est, en moyenne, davantage en adéquation avec la perception du

système par le participant.

## 5.2 Perspectives

L'une des perspectives immédiates de la seconde étude serait d'étudier l'adaptation des participants au travers des données gestuelles récoltées. On pourrait par exemple chercher à voir si l'exécution des gestes évolue au fil des itérations de la phase de performance et au fil des progrès du système.

Un autre enrichissement de ce travail serait d'utiliser d'autres mesures que le taux de prédiction correcte ou la précision afin d'évaluer d'autres aspects des performances de classification.

Par ailleurs, on précise dans l'état de l'art que les performances de l'apprentissage actif dépendent grandement du modèle d'apprentissage machine utilisé (Pereira-Santos, Prudêncio, and Carvalho, 2017). Il serait donc intéressant de réaliser la même étude avec de nouveaux modèles.

Par ailleurs, les classifieurs utilisés sont peu expressifs. On pourrait utiliser des modèles plus adaptés au mouvement comme les modèles de Markov cachés (HMM) qui modélisent la dynamique du geste et permettent de suivre la progression d'un geste au travers des états du modèle. De plus, on pourrait tirer des modèles génératifs (comme un modèle de Markov caché avec émissions de mélanges gaussiens par exemple) pour explorer de nouveaux scénarios d'acquisition des données comme les requêtes par synthèse (présentés à la section 2.1.2). De plus, l'expressivité des modèles génératifs complexifieraient les retours d'informations du système et l'étude de la perception des participants des limites du système. Ces modèles pourraient permettre de concevoir des systèmes appliqués à la création artistique, où la tâche n'est pas définie à l'avance. Dans ce contexte, les réponses de l'humain aux requêtes du système pourraient être plus subjectives et complexes, amenant de nouvelles problématiques de recherches sur la perception humaine.

# Bibliographie

- Amershi, Saleema et al. (2014). "Power to the people: The role of humans in interactive machine learning". In: *AI Magazine* 35.4, pp. 105–120.
- Angluin, Dana (1988). "Queries and concept learning". In: *Machine learning* 2.4, pp. 319–342.
- Atlas, Les E, David A Cohn, and Richard E Ladner (1990). "Training connectionist networks with queries and selective sampling". In: *Advances in neural information processing systems*, pp. 566–573.
- Bolt, Richard A and Edward Herranz (1992). "Two-handed gesture in multi-modal natural dialog". In: *Proceedings of the 5th annual ACM symposium on User interface software and technology*. ACM, pp. 7–14.
- Boukhelifa, Nadia, Anastasia Bezerianos, and Evelyne Lutton (2018). "Evaluation of Interactive Machine Learning Systems". In: *arXiv preprint arXiv:1801.07964*.
- Cakmak, Maya, Crystal Chao, and Andrea L Thomaz (2010). "Designing interactions for robot active learners". In: *IEEE Transactions on Autonomous Mental Development* 2.2, pp. 108–118.
- Calinon, Sylvain et al. (2010). "Learning and reproduction of gestures by imitation". In: *IEEE Robotics & Automation Magazine* 17.2, pp. 44–54.
- Caramiaux, Baptiste, Marco Donnarumma, and Atau Tanaka (2015). "Understanding gesture expressivity through muscle sensing". In: *ACM Transactions on Computer-Human Interaction (TOCHI)* 21.6, p. 31.
- Caramiaux, Baptiste, Marcelo M Wanderley, and Frédéric Bevilacqua (2012). "Segmenting and parsing instrumentalists' gestures". In: *Journal of New Music Research* 41.1, pp. 13–29.
- Cohen, Philip R et al. (1997). "Quickset: Multimodal interaction for distributed applications". In: *Proceedings of the fifth ACM international conference on Multimedia*. ACM, pp. 31–40.
- Cohn, David, Les Atlas, and Richard Ladner (1994). "Improving generalization with active learning". In: *Machine learning* 15.2, pp. 201–221.
- Cohn, David A (1994). "Neural network exploration using optimal experiment design". In: *Advances in neural information processing systems*, pp. 679–686.
- Dasgupta, Sanjoy (2011). "Two faces of active learning". In: *Theoretical computer science* 412.19, pp. 1767–1781.
- Donmez, Pinar and Jaime G Carbonell (2008). "Proactive learning: cost-sensitive active learning with multiple imperfect oracles". In: *Proceedings of the 17th ACM conference on Information and knowledge management*. ACM, pp. 619–628.
- Dos Santos, Davi P and André CPLF de Carvalho (2015). "Selectively inhibiting learning bias for active sampling". In: *Intelligent Systems (BRACIS), 2015 Brazilian Conference on*. IEEE, pp. 62–67.
- Fails, Jerry Alan and Dan R Olsen Jr (2003). "Interactive machine learning". In: *Proceedings of the 8th international conference on Intelligent user interfaces*. ACM, pp. 39–45.
- Fdili Alaoui, Sarah et al. (2013). "Dance interaction with physical model visuals based on movement qualities". In: *International Journal of Arts and Technology* 6.4, pp. 357–387.
- Feng, Yinfu et al. (2012). "Active learning for social image retrieval using Locally Regressive Optimal Design". In: *Neurocomputing* 95, pp. 54–59.
- Ferdowsi, Zahra, Rayid Ghani, and Mohit Kumar (2011). "An online strategy for safe active learning". In: *ICML workshop on combining learning strategies to reduce label cost*. Vol. 2. 4, pp. 2–4.



- Fiebrink, Rebecca and Baptiste Caramiaux (2016). "The machine learning algorithm as creative musical tool". In: *Handbook of Algorithmic Music*.
- Fiebrink, Rebecca, Perry R Cook, and Dan Trueman (2011). "Human model evaluation in interactive supervised learning". In: *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*. ACM, pp. 147–156.
- Fiebrink, Rebecca, Dan Trueman, and Perry R Cook (2009). "A Meta-Instrument for Interactive, On-the-Fly Machine Learning." In: *NIME*, pp. 280–285.
- Françoise, Jules (2013). "Gesture–sound mapping by demonstration in interactive music systems". In: *Proceedings of the 21st ACM international conference on Multimedia*. ACM, pp. 1051–1054.
- (2015). "Motion-sound mapping by demonstration". PhD thesis. UPMC.
- Freeman, Linton C (1965). *Elementary applied statistics: for students in behavioral science*. John Wiley & Sons.
- Freeman, William T and Craig D Weissman (1997). *Hand gesture machine control system*. US Patent 5,594,469.
- Fujii, Atsushi et al. (1998). "Selective sampling for example-based word sense disambiguation". In: *Computational Linguistics* 24.4, pp. 573–597.
- Gal, Yarín (2016). "Uncertainty in deep learning". In: *University of Cambridge*.
- Gal, Yarín, Riashat Islam, and Zoubin Ghahramani (2017). "Deep bayesian active learning with image data". In: *arXiv preprint arXiv:1703.02910*.
- Guo, Yuhong and Russell Greiner (2007). "Optimistic Active-Learning Using Mutual Information." In: *IJCAI*. Vol. 7, pp. 823–829.
- Houlsby, Neil et al. (2011). "Bayesian active learning for classification and preference learning". In: *arXiv preprint arXiv:1112.5745*.
- Iannizzotto, Giancarlo, Massimo Villari, and Lorenzo Vita (2001). "Hand tracking for human-computer interaction with graylevel visualglove: Turning back to the simple way". In: *Proceedings of the 2001 workshop on Perceptive user interfaces*. ACM, pp. 1–7.
- Körner, Christine and Stefan Wrobel (2006). "Multi-class ensemble-based active learning". In: *European conference on machine learning*. Springer, pp. 687–694.
- Lewis, David D and Jason Catlett (1994). "Heterogeneous uncertainty sampling for supervised learning". In: *Machine Learning Proceedings 1994*. Elsevier, pp. 148–156.
- Lewis, David D and William A Gale (1994). "A sequential algorithm for training text classifiers". In: *Proceedings of the 17th annual international ACM SIGIR conference on Research and development in information retrieval*. Springer-Verlag New York, Inc., pp. 3–12.
- Lindenbaum, Michael, Shaul Markovitch, and Dmitry Rusakov (2004). "Selective sampling for nearest neighbor classifiers". In: *Machine learning* 54.2, pp. 125–152.
- Lomasky, Rachel et al. (2007). "Active class selection". In: *European Conference on Machine Learning*. Springer, pp. 640–647.
- Maiora, Josu, Borja Ayerdi, and Manuel Graña (2014). "Random forest active learning for AAA thrombus segmentation in computed tomography angiography images". In: *Neurocomputing* 126, pp. 71–77.
- Mancini, Maurizio and Ginevra Castellano (2007). "Real-time analysis and synthesis of emotional gesture expressivity". In: *Proc. of the Doctoral Consortium of Intl. Conf. on Affective Computing and Intelligent Interaction*. Citeseer.
- Missoum, Samy, Christophe Vergez, and Jean-Baptiste Doc (2014). "Explicit mapping of acoustic regimes for wind instruments". In: *Journal of Sound and Vibration* 333.20, pp. 5018–5029.
- Pea, Roy D (1986). "User centered system design: New perspectives on human-computer interaction". In:
- Pereira-Santos, Davi, Ricardo Bastos Cavalcante Prudêncio, and André CPLF de Carvalho (2017). "Empirical investigation of active learning strategies". In: *Neurocomputing*.

- Pogorelc, Bogdan, Zoran Bosnić, and Matjaž Gams (2012). "Automatic recognition of gait-related health problems in the elderly using machine learning". In: *Multimedia Tools and Applications* 58.2, pp. 333–354.
- Prince, Michael (2004). "Does active learning work? A review of the research". In: *Journal of engineering education* 93.3, pp. 223–231.
- Ramirez-Loaiza, Maria E et al. (2017). "Active learning: an empirical study of common baselines". In: *Data Mining and Knowledge Discovery* 31.2, pp. 287–313.
- Rautaray, Siddharth S and Anupam Agrawal (2015). "Vision based hand gesture recognition for human computer interaction: a survey". In: *Artificial Intelligence Review* 43.1, pp. 1–54.
- Roy, Nicholas and Andrew McCallum (2001). "Toward optimal active learning through monte carlo estimation of error reduction". In: *ICML, Williamstown*, pp. 441–448.
- Scheffer, Tobias, Christian Decomain, and Stefan Wrobel (2001). "Active hidden markov models for information extraction". In: *International Symposium on Intelligent Data Analysis*. Springer, pp. 309–318.
- Schein, Andrew Ian and Lyle H Ungar (2005). *Active learning for logistic regression*. University of Pennsylvania.
- Settles, Burr (2009). *Active Learning Literature Survey*. Computer Sciences Technical Report 1648. University of Wisconsin–Madison.
- Settles, Burr and Mark Craven (2008). "An analysis of active learning strategies for sequence labeling tasks". In: *Proceedings of the conference on empirical methods in natural language processing*. Association for Computational Linguistics, pp. 1070–1079.
- Shannon, Claude Elwood (2001). "A mathematical theory of communication". In: *ACM SIG-MOBILE mobile computing and communications review* 5.1, pp. 3–55.
- Simard, Patrice Y et al. (2017). "Machine Teaching: A New Paradigm for Building Machine Learning Systems". In: *arXiv preprint arXiv:1707.06742*.
- Tong, Simon and Daphne Koller (2001). "Support vector machine active learning with applications to text classification". In: *Journal of machine learning research* 2.Nov, pp. 45–66.
- Wu, Dongrui and Thomas D Parsons (2011). "Active class selection for arousal classification". In: *Affective Computing and Intelligent Interaction*. Springer, pp. 132–141.
- Xiong, Wei et al. (2014). "Active learning for protein function prediction in protein–protein interaction networks". In: *Neurocomputing* 145, pp. 44–52.
- Zhang, Xiao-Yu et al. (2015). "Update vs. upgrade: modeling with indeterminate multi-class active learning". In: *Neurocomputing* 162, pp. 163–170.
- Zhong, Bineng et al. (2014). "Visual tracking via weakly supervised learning from multiple imperfect oracles". In: *Pattern Recognition* 47.3, pp. 1395–1410.
- Zhu, Xiaojin, John Lafferty, and Ronald Rosenfeld (2005). "Semi-supervised learning with graphs". PhD thesis. Carnegie Mellon University, language technologies institute, school of computer science.

# Liste des Figures

1.1	Rétroactions lors d'un processus d'apprentissage machine interactif. . . . .	2
2.1	Récapitulatif non exhaustif des approches et des stratégies d'apprentissage actif. Les méthodes encadrées en orange sont celles qui seront étudiées dans nos travaux. Leur choix est justifié à la page ?? . . . . .	11
2.2	Configuration d'apprentissage actif avec un humain dans la boucle. La stratégie d'échantillonnage dépend de l'ensemble $\mathcal{U}$ dans pour les stratégies agnostiques et dépend du modèle d'apprentissage machine pour les stratégies non-agnostiques. . . . .	15
3.1	Photographie du dispositif et d'un individu en train de l'utiliser (non participant). Les données gestuelles sont issues des capteurs du smart-phone. Celles-ci sont envoyées à l'ordinateur qui les enregistre dans un fichier. Le mobile est tenu dans la main dominante de l'utilisateur et la main non-dominante permet de démarrer et d'arrêter l'enregistrement d'un geste. . . . .	18
3.2	Données issues des capteurs, affichées pour un geste. . . . .	19
3.3	Partitionnement de la base de donnée $\mathcal{B}$ durant la validation croisée. La flèche indique le transfert des instances de l'ensemble $\mathcal{U}$ à $\mathcal{L}$ après une requête. . . . .	20
3.4	Taux de prédiction correcte moyenné sur les participants en fonction du nombre de requêtes pour 3 stratégies d'apprentissage actif (Random, Margin et ATU), 4 classifieurs (SVM, KNN, RF et NB) et pour un ensemble de données composées de 5 lettres cursives de l'alphabet romain (z, m, k, u, p) dessinées en l'air avec la main dominante. . . . .	22
3.5	Distribution des classes (lettres) lors de l'apprentissage actif sur les données d'un seul participant, pour les trois stratégies (Random, Margin et ATU), pour 2 classifieurs (SVM et KNN) et pour 5 lettres de l'alphabet. . . . .	23
3.6	Distribution des classes (lettres) lors de l'apprentissage actif sur les données d'un autre participant, pour les trois stratégies (Random, Margin et ATU), pour 2 classifieurs (RF et NB) et pour 5 lettres de l'alphabet. . . . .	23
4.1	Schéma du routage des données de la seconde étude. . . . .	28
4.2	Schéma du déroulement de l'expérience. . . . .	28
4.3	Interface lors de la phase d'initialisation . . . . .	29
4.4	Interface lors de la phase de performance . . . . .	30
4.5	Dispositif d'enregistrement des gestes lors de la phase de performance . . . . .	30
4.6	Taux de prédiction correcte lors des 4 itérations de la phase de performance de l'expérience, moyennées sur les participants et pour les trois stratégies d'apprentissage actif. . . . .	32
4.7	Corrélation de Pearson entre les évaluations subjectives des participants et la distribution des classes demandées par l'algorithme lors de la phase d'enseignement, en fonction des 4 itérations et moyennées sur les participants, pour 3 stratégies d'apprentissage actif (Random, Margin et ATU) . . . . .	34

4.8	Corrélation de Pearson entre les évaluations subjectives et la distribution des classes demandées par l'algorithme lors de la phase d'enseignement, concaténées sur les 4 itérations et moyennées sur les participants, pour 3 stratégies d'apprentissage actif (Random, Margin et ATU) . . . . .	35
4.9	Distributions des classes (lettres) de l'ensemble d'entraînement au cours de l'expérience, pour les trois stratégies (Random, Margin et ATU) et pour 5 gestes du vocabulaire, moyennées parmi les participants. . . . .	36
4.10	Corrélation de Pearson entre l'écart-type de la matrice de confusion et la distribution des classes demandées par l'algorithme lors de la phase d'enseignement, concaténées sur les 4 itérations et moyennées sur les participants, pour 3 stratégies d'apprentissage actif (Random, Margin et ATU) . . . . .	38
4.11	Corrélation de Pearson entre les évaluations subjectives et la distribution des classes de gestes choisies par le participant lors de la phase de performance, concaténées sur les 4 itérations et moyennées sur les participants, pour 3 stratégies d'apprentissage actif (Random, Margin et ATU) . . . . .	39
4.12	Taux de prédiction correcte (ligne du haut) et corrélation entre les évaluations subjectives et les classes demandées dans les requêtes (ligne du bas) lors des 4 itérations de la phase de «Performance» de l'expérience, pour 5 participants isolés et pour les trois stratégies d'apprentissage actif (Random, Margin et ATU)	40
4.13	Distribution des classes (lettres) de l'ensemble d'entraînement au cours de l'expérience, pour les trois stratégies (Random, Margin et ATU) et pour 5 gestes du vocabulaire, pour 5 participants isolés. . . . .	40
A.1	Évaluation demandée au participant à la fin de chaque phase de performance. . .	51
B.1	Taux de prédiction correcte pour 3 stratégies d'apprentissage actif (Random, Margin et ATU), 2 classifieurs (SVM et KNN) et pour un ensemble de données composées des lettres cursives de l'alphabet romain dessinées en l'air avec la main dominante (26 classes). . . . .	52

## Annexe A

# Fiche d'évaluation donnée aux participants de la seconde étude

P - Does the algorithm correctly predict your gestures? Passe :

z  Never        Always

m  Never        Always

k  Never        Always

u  Never        Always

p  Never        Always

FIG A.1: Évaluation demandée au participant à la fin de chaque phase de performance.

## Annexe B

# Analyse préliminaire de la première étude

La figure B présente une analyse du taux de prédiction correcte pour une base de données de 780 gestes : 26 classes (les lettres de l'alphabet latin) et 30 gestes par classe. L'analyse par validation croisée est identique à celle décrite à la section 3.1.3.

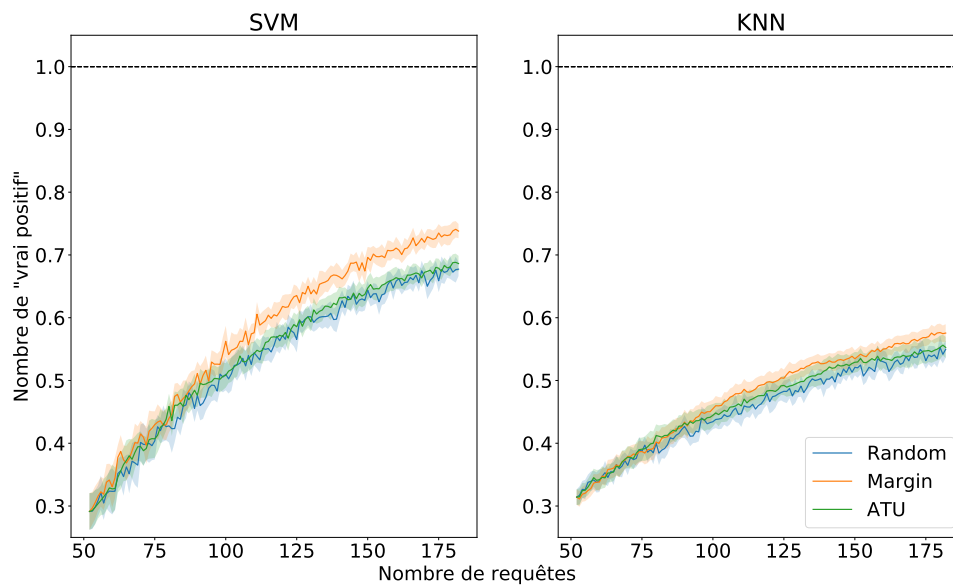


FIG B.1: Taux de prédiction correcte pour 3 stratégies d'apprentissage actif (Random, Margin et ATU), 2 classifieurs (SVM et KNN) et pour un ensemble de données composées des lettres cursives de l'alphabet romain dessinées en l'air avec la main dominante (26 classes).