Équité et étiquetage dans les problèmes multi-classes[1]

Titre : Docteur en mathématiques appliquées spécialisé dans l'apprentissage statistique, en post-doctorat à l'Université de Montréal et enseignant en Data Science à l'Institut du Risk Management (IRM) ainsi qu'à l'EPITA en statistiques et informatique.

Mots clés : Classification, Apprentissage Semi-Supervisé, Apprentissage Actif, Équité Algorithmique, Actuariat.

L'Intelligence Artificielle (IA) est devenue un élément clé du secteur de l'assurance grâce à l'explosion des données disponibles et à la croissance de la puissance de calcul. Le Machine Learning (ML) offre de nombreuses applications qui permettent d'améliorer l'efficacité opérationnelle et l'évaluation des risques tout en réduisant les coûts pour les entreprises. Parmi les avantages significatifs de cette technologie, on peut citer une segmentation plus précise du risque pour la tarification des contrats, une automatisation à grande échelle et une amélioration de la prise de décision pour le traitement des documents textuels.

Cependant, l'utilisation de cette masse de données soulève des questions éthiques et de réglementation, notamment en matière de protection des données, telles que celles stipulées par le Règlement Général sur la Protection des Données (RGPD). Le respect des normes RGPD est essentiel pour éviter toute violation éthique, qui pourrait entraîner l'impossibilité pour l'assureur de conserver ces données. Ces informations doivent être étiquetées de manière adéquate pour permettre leur utilisation dans des modèles ML, mais ce processus peut être coûteux et ne pas être adapté à la gestion de grands volumes de données ou à une gestion de l'information en temps quasi-réel. Par conséquent, pour répondre à ces défis, la mise en place d'un système d'apprentissage précis (en termes de prédiction), peu coûteux (en termes d'étiquetage) et éthique (en termes d'équité) est nécessaire dans le secteur de l'assurance.

Ainsi, pour répondre à ces difficultés, une solution éthique et peu coûteuse pour la gestion de grands volumes de données est nécessaire dans le secteur de l'assurance. Cette thèse résout certains de ces défis pour des problèmes multi-classes en proposant un système d'apprentissage performant qui offre une solution adaptée (précision, équité et coût). En fin de compte, l'adoption de ces nouvelles méthodologies et la mise en place d'un système d'apprentissage efficace peuvent aider les assureurs à renforcer leur compétitivité et à répondre aux défis actuels du marché.

Améliorer l'étiquetage en assurance via l'apprentissage actif

L'assurance doit faire face à de nombreux défis liés à l'utilisation de l'IA, dont le coût élevé de l'étiquetage des données constitue la première difficulté. En effet, l'obtention de données étiquetées de qualité nécessite souvent l'intervention d'experts coûteux en temps et en ressources financières. Les campagnes d'étiquetage sont donc généralement effectuées dans des délais restreints, ce qui réduit leur volume. Ainsi, il est crucial de disposer d'algorithmes efficaces pour prioriser les données à étiqueter. L'approche de l'apprentissage actif (AL) offre une solution à ce problème à base d'interaction homme-machine. L'AL peut être défini de manière informelle comme une boucle de rétroaction entre l'inférence d'un modèle ML et un expert humain (oracle). En particulier, cette méthodologie propose une solution naturelle pour les données non structurées (images, textes, sons, …) telles que les images de véhicules endommagés, les données télématiques, la conformité GDPR, les rapports médicaux ou les descriptions d'accidents, qui nécessitent toutes l'intervention de professionnels qualifiés.

Il est important de noter que l'AL peut également être appliqué aux données structurées ou tabulaires. Cependant, la communauté actuarielle n'a pas encore pleinement exploité cette

[1] Cet article est tiré de la thèse présentée par l'auteur en juin 2022

approche malgré son potentiel pour de nombreux cas d'utilisation pratiques, notamment la détection de la fraude et la segmentation des risques. Pour la détection de la fraude, l'AL permet de sélectionner les cas les plus pertinents de sinistres frauduleux ou non-frauduleux à étiqueter par des experts. Cette approche permet d'améliorer la précision des modèles de détection de la fraude, ce qui réduit les pertes financières pour les compagnies d'assurance. En ce qui concerne l'évaluation des risques, l'AL peut être utilisé pour évaluer les niveaux de risque de différents assurés dans une tâche multi-classes. En sélectionnant les exemples les plus pertinents et informatifs, les compagnies peuvent améliorer la précision de leurs modèles de prédiction et mieux identifier les assurés susceptibles de déposer une demande d'indemnisation. En réétiquetant ces exemples, les compagnies peuvent également ajuster les primes des assurés en fonction de leur profil de risque, ce qui contribue à la juste tarification des polices d'assurance et à la réduction des coûts liés aux demandes d'indemnisation.

Notre étude a pour objectif de démontrer comment l'AL peut améliorer la science actuarielle traditionnelle en mettant en évidence ses avantages pratiques pour les données structurées et non structurées, y compris l'analyse des sentiments à partir des données *Net Promoter Score* (NPS). En particulier, notre étude explore diverses méthodologies d'échantillonnage classiques avant d'évaluer leur performance sur des ensembles de données d'assurance synthétiques et réelles, visant ainsi à combler le fossé entre l'AL et l'actuariat.

Optimisation de l'étiquetage de données par une approche de contrôle stochastique

Traditionnellement, en AL, la pratique courante est la sélection itérative d'une instance à étiqueter suivie d'un ajustement du modèle ML sur l'ensemble des données étiquetées. Cependant, l'attente des experts humains pour réétiqueter de nouvelles instances à chaque cycle d'AL peut prendre des heures pour les modèles complexes tels que les réseaux de neurones. Cette inquiétude est exacerbée lorsque plusieurs experts travaillent en parallèle. Pour améliorer l'interaction homme-machine, une technique consiste à étiqueter un lot d'instances plutôt qu'une seule par cycle d'AL. Néanmoins, cela peut nuire à la performance prédictive du modèle en réduisant le nombre d'itérations pour un budget d'étiquetage donné.

Notre étude en AL se concentre sur la détermination optimale de la taille de lots d'instances à étiqueter pour améliorer la performance du modèle tout en réduisant le temps d'attente des experts humains. Bien que certains articles récents soulignent l'importance de définir la taille à l'avance pour maximiser la performance du modèle, aucun des travaux précédents n'a pris en compte le compromis entre cette performance et le coût d'attente de la procédure d'AL. Dans ce contexte, nous formulons ce problème comme un problème de contrôle stochastique, où la qualité (ou performance) du modèle $(Q_t)_t$ est un processus stochastique dans $[0,1]$ contrôlé par la taille du lot d'instances $(b_t)_t$ dans $[0,B_{max}]$ où B_{max} correspond au budget total d'étiquetage et B_t le budget consommé au temps t. Nous utilisons une approche basée sur le principe de programmation dynamique pour résoudre ce problème et déterminons l'équation aux dérivées partielles de Hamilton-Jacobi-Bellman (HJB). En particulier, $(Q_t)_t$ est supposé satisfaire une équation différentielle stochastique (EDS) dirigée par un mouvement brownien $(W_t)_t$, dont les coefficients (μ, σ) dépendent de (B_t, b_t). La dynamique des processus d'état (Q, B) est définie par :

$$dQ_t = \mu(B_t, b_t) \cdot Q_t(1 - Q_t) \cdot dt + \sigma(B_t, b_t) \cdot Q_t(1 - Q_t) \cdot dW_t$$

$$dB_t = b_t \cdot dt\,.$$

Comme il est usuel, nous définissons une fonction d'utilité régulière concave $\mathscr{U}$ qui modélise l'aversion au risque de l'utilisateur concernant la performance du modèle et un coût supposé être une fonction convexe $\mathscr{C}$ de la taille du lot b. A partir de ces formalisations, et en posant

le temps d'arrêt $\tau = inf\{t \geq 0 \,|\, B_t = B_{max} ou\ Q_t = 0\ ou\ Q_t = 1\}$, nous formulons notre problème d'optimisation comme suit : $\sup_{(b_s)} \mathbb{E}\left[\mathscr{U}(Q_\tau) - \int_0^\tau \mathscr{C}(b_s)ds\right]$. Le budget consommé $B_t = \int_0^{t\wedge\tau} b_s ds$ est un nombre réel positif compris entre 0 (aucune instance étiquetée) et B_{max} (épuisement du budget d'étiquetage). Nous résolvons l'équation aux dérivées partielles de HJB correspondante, ce qui nous permet de développer une méthodologie améliorée d'AL qui offre des avantages significatifs. Des analyses et des simulations numériques ont été menées pour déterminer une stratégie optimale d'étiquetage, qui réduit considérablement le nombre d'itérations d'AL tout en préservant la performance du modèle. Par conséquent, notre méthodologie représente une amélioration importante des conditions d'étiquetage pour les experts humains et offre une solution pour les problèmes d'apprentissage avec un budget d'étiquetage limité.

Renforcer l'équité algorithmique en multi-classes

L'équité dans l'inférence de l'apprentissage automatique est une question cruciale étant donné que les modèles peuvent reproduire les inégalités et les discriminations présentes dans les données. Les assureurs de l'Union Européenne sont légalement tenus de respecter le principe d'équité, comme stipulé par la décision de la Cour de justice européenne du 21 décembre 2012, et les nouvelles directives de l'*Insurance Distribution Directive* imposent également le principe d'équité dans le traitement des données. Le développement d'un cadre de gouvernance de l'IA devient donc essentiel pour atténuer ou éliminer certains problèmes éthiques, dont l'équité des modèles d'apprentissage est l'un des défis majeurs.

Les systèmes d'IA apprennent à prendre des décisions sur la base de données étiquetées, qui peuvent inclure des décisions humaines biaisées ou refléter des inégalités sociales, même si les variables sensibles sont supprimées. Il est crucial de souligner qu'en assurance ces critères discriminatoires peuvent entraîner des primes désavantageuses pour certains groupes défavorisés, ce qui peut les amener à résilier leurs contrats en faveur d'autres organismes d'assurance plus équitables. De plus, conformément au RGPD, les organismes d'assurance peuvent être sanctionnés jusqu'à 4 % de leur chiffre d'affaires annuel. Par conséquent, il est primordial de s'assurer que les algorithmes de tarification (problème multi-classes) proposés n'utilisent pas ces critères discriminatoires et que des mesures sont mises en place pour garantir une équité dans les décisions prises par les modèles d'IA.

Dans cette thèse, nous présentons différentes méthodologies d'équité algorithmique visant à réduire l'influence des biais dans les données. Bien que l'équité algorithmique soit un domaine bien établi en ML, peu d'études ont abordé la classification multi-classes du point de vue de l'équité. Nous proposons une extension des définitions exactes et approximatives de l'équité à la Parité démographique pour la classification multi-classes, et nous définissons les classifieurs équitables optimaux correspondants. Notons que l'obtention d'un classifieur équitable optimal nécessite d'équilibrer correctement le risque de mauvaise classification et le critère d'équité. Pour résoudre ce problème, nous proposons une formulation du Lagrangien qui permet de minimiser le risque tout en satisfaisant le critère d'équité. Formellement, pour une équité exacte le Lagrangien (avec $(\lambda_k)_k$ les multiplicateurs de Lagrange) s'écrit :

$$\mathscr{R}_\lambda(g) := \mathbb{P}\left(g(X,S) \neq Y\right) + \sum_{k=1}^{K} \lambda_k [\mathbb{P}\left(g(X,S) = k \,|\, S = 1\right) - \mathbb{P}\left(g(X,S) = k \,|\, S = -1\right)],$$

avec (X, S, Y) un n-uplet aléatoire avec la distribution $\mathbb{P}$, où $X \in \mathcal{X}$ est un sous-ensemble de $\mathbb{R}^d$ qui représente les variables non sensibles, $S \in \mathcal{S} := \{-1,1\}$ est une variable sensible, considérée comme discrète, sur laquelle nous aimerions imposer l'équité (par exemple le genre ou l'appartenance ethnique), et $Y \in [K] := \{1,\ldots,K\}$ la tâche à estimer, K étant un nombre fixe de classes. Sous des conditions de continuité, nous déterminons les multiplicateurs de Lagrange optimaux λ_k^* et le prédicteur équitable optimal g^* qui minimise $\mathcal{R}_{\lambda^*}(g)$. La résolution du problème d'équité approximative présente des similitudes avec le cas de l'équité exacte (se référer au manuscrit de thèse pour plus de détails). Notre solution d'équité repose sur une procédure *plug-in* pour laquelle nous avons établi des garanties théoriques démontrant que notre estimateur reproduit le comportement de la règle optimale en termes d'équité et de risque. Nous avons évalué cette approche sur des données synthétiques et réelles, et les résultats montrent une grande efficacité pour atteindre un niveau d'injustice prédéfini. Ces résultats suggèrent que notre méthodologie peut contribuer à réduire les biais et les inégalités dans les classifications multi-classes et ainsi promouvoir des décisions plus justes et équitables.

Partenariat entre CREST et Société Générales Assurances

Cette thèse CIFRE découle d'une collaboration de recherche entre le Laboratoire Finance-Assurance (LFA) du CREST et le service DataLab de Société Générale Assurances. Avec la démocratisation croissante des modèles ML, l'objectif de ce projet de recherche et développement est de renforcer la gouvernance de l'IA chez Société Générale Assurances, en particulier en veillant à l'équité des systèmes d'IA.