

Détection de la dérive dans un contexte non supervisé

Fucellaro, Maxime, maxime.fucellaro@u-bordeaux.fr, Université de Bordeaux, CNRS, Bordeaux INP, LaBRI, Bordeaux

Simon, Laurent, laurent.simon@u-bordeaux.fr, Université de Bordeaux, CNRS, Bordeaux INP, LaBRI, Bordeaux
Zemmari, Akka, akka.zemmari@u-bordeaux.fr, Université de Bordeaux, CNRS, Bordeaux INP, LaBRI, Bordeaux

Thématique : Intelligence Artificielle

Résumé : La dérive conceptuelle se traduit par une baisse rapide des performances des modèles prédictifs. Bien que plusieurs méthodes permettent aujourd'hui de détecter une dérive, il est souvent nécessaire d'avoir accès à la vérité terrain. Nous passerons en revue les différentes méthodologies existantes avant de présenter nos travaux basés sur une détection non supervisé de la dérive.

Mots clés : Dérive conceptuelle, non-supervisé, modèles en production

1. Introduction

La dérive est définie comme un changement de la distribution conditionnelle des cibles par rapport aux agrégats. La détection de la dérive est un enjeu majeur pour les modèles en production. En effet, lors de l'apparition d'une dérive, les modèles ne sont plus en mesure d'inférer correctement. Mangrove, dont la spécialité est la mise en production de modèles prédictifs était systématiquement confronté à ces enjeux. Une thèse Cifre a été financé dont l'objectif est d'apporter une solution industrialisable à la détection de la dérive.

La dérive conceptuelle est un sujet de recherche très actif. Un grand nombre de modèle de détections se basent sur une observation du taux d'erreur. Lors d'une baisse en performance d'un modèle, on constate une dérive. Cependant, malgré un bon niveau de performances, ces approches nécessitent d'avoir la vérité terrain pour fonctionner. Quand celle-ci n'est pas immédiatement disponible, la dérive n'est pas détectable. Fort de ce constat nous avons travaillé sur un détecteur qui fonctionne indépendamment de la disponibilité des labels.

2. Méthodologie

Afin de lier le changement de distribution que l'on peut quantifier et la dérive, nous nous basons sur un partitionnement de l'espace en fonction des labels via un arbre de décision. L'arbre ne va garder que les feuilles pures qui contiennent un nombre suffisamment grand d'observations. Les feuilles ne respectant pas ces conditions sont élaguées. À chaque feuille valide est associé les observations d'entraînement lui appartenant.

Lors de la phase d'inférence, les observations non labélisés sont associées aux feuilles. Une comparaison entre les distributions d'entraînement et d'inférence au sein de chaque sous-ensemble à l'aide d'indicateurs statistiques est faite. Si un changement local de distribution est détecté dans suffisamment de sous ensemble, alors, on est en présence d'une dérive. Une double pondération des feuilles et de l'amplitude du changement permet une amélioration du niveau de détection. Cette méthode nous permet de ne pas faire usage de la vérité terrain lors de la phase d'inférence. Des benchmarks nous permettent d'affirmer que notre algorithme surpasse l'état de l'art sur un ensemble de jeux de données classiques dans le domaine de la dérive.

3. Originalité / perspective

Notre méthode de détection se différencie de l'état de l'art car on ne fait pas usage de la vérité terrain pour déceler la présence d'une dérive qui impacte les performances prédictives soit la distribution $P(y | X)$. D'autres méthodologies ne font pas usage de la vérité terrain, mais ces méthodes sont aujourd'hui bornées à la détection d'une dérive sur l'espace des variables, qui pas les performances prédictives.

Les prochaines étapes seront d'évaluer notre algorithme avec l'état de l'art sur des jeux de données réels issues de l'industrie, de continuer nos travaux de recherche sur le détecteur de dérive afin de le rendre plus robuste vis-à-vis des faux positifs.

Références

Fucellaro, M., Simon, L., & Zemmari, A. Partially Supervised Classification for Early Concept Drift Detection, ICTAI, 2022

Fucellaro, M., Simon, L., & Zemmari, A. A Robust Drift Detection Algorithm with High Accuracy and Low False Positives Rate, SafeAI@AAAI, (2023)

Baena-Garcia, M., del Campo-Ávila, J., Fidalgo, R., Bifet, A., Gavalda, R., & Morales-Bueno, R. (2006, September). Early drift detection method

Castellani, A., Schmitt, S., & Hammer, B. (2021, December). Task-Sensitive Concept Drift Detector with Constraint Embedding.

Cerqueira, V., Gomes, H. M., Bifet, A., & Torgo, L. (2022). STUDD: a student–teacher method for unsupervised concept drift detection.