

Prise en compte de données séquentielles hétérogènes dans l'apprentissage profond : application aux données de soins intensifs

Mamadou Ben Hamidou Cissoko*, Vincent Castelain**, Nicolas Lachiche*

* ICube, Université de Strasbourg,

** Hôpitaux Universitaires de Strasbourg

1 Problématique

L'adoption généralisée des dossiers médicaux électroniques (DME) augmente l'intérêt pour les algorithmes d'apprentissage machine (ML) dans le domaine médical. Les données extraites du DME présentent souvent un grand nombre de valeurs manquantes pour les variables cliniques car les prélèvements de ces variables sont effectués à intervalles de temps irréguliers. Cela s'explique souvent par manque de collecte ou selon l'état sous-jacent du patient. Afin de résoudre ce problème, plusieurs stratégies ont été utilisées allant des méthodes d'imputation basées sur les noyaux, des procédures statistiques de base pour l'imputation, telles que le zéro, la moyenne à des stratégies permettant de directement modéliser les observations contenant des valeurs manquantes. (Rajkomar et al., 2018; Song et al., 2018) ont proposé une méthode générale pour représenter ces séries temporelles d'événements multivariés irréguliers en séries temporelles régulières non biaisées en agrégeant les mesures en intervalles de temps discrets pour chaque variable médicale à chaque épisode de soins pour créer des séries temporelles multivariées avec un intervalle de temps régulier.

2 Approche proposée

Nous proposons un réseau neuronal multimodal basée sur LSTM capable de gérer la nature des irrégularités présentes dans les données DME, tant au niveau temporel qu'au niveau des caractéristiques mesurées. Il prends en entrée les données des patients et les indicateurs binaires de l'absence de chaque variable à chaque pas de temps (les données sont modélisées par heure). Nous montrons l'efficacité de l'approche proposée sur deux tâches médicales de référence (mortalité et durée de séjour) utilisant des données cliniques réelles dérivées des DME (MIMIC-III) (Johnson et al., 2016) pour des patients ayant séjourné dans les différentes unités des soins intensifs.

TAB. 1 – TD-LSTM-ICU VS SAnD on (MORTALITY & LOS) TASKS : 48 HOURS DATA

TASKS	TD-LSTM-ICU		SAnD	
	SAPS II FEATURES	ALL FEATURES	SAPS II FEATURES	ALL FEATURES
HOSPITAL-MORTALITY (F1-Score)	0.61	0.63	0.59	0.61
ICU-MORTALITY (F1-Score)	0.62	0.66	0.60	0.64
LOS (MAE)	1.951 ± 0.057	1.925 ± 0.076	3.177 ± 0.155	3.172 ± 0.15
LOS (RMSE)	5.374 ± 0.06	5.323 ± 0.078	6.947 ± 0.088	6.942 ± 0.086

3 Résultats

Nous comparons notre approche à celle proposé dans (Song et al., 2018). Nous nous posons également la question de l'impact de l'utilisation de différents ensembles de caractéristiques et de la durée d'observation sur la performance de prédiction. nous indiquons la moyenne et l'écart type de 5 plis pour les tâches de prédiction.

La table 1 montre les résultats de notre approche par rapport à celle définie dans (Song et al., 2018) en utilisant deux ensembles des caractéristiques A ou B utilisées comme variables d'entrées. Ainsi, nous constatons que notre modèle surpasse celui proposé dans (Song et al., 2018) sur les deux tâches de prédictions de plus de 2%. Nous effectuons également le même constat sur la tache de la durée de séjour où notre approche obtient de meilleures performances en termes d'erreur quadratique moyenne (en jours). De par ces résultats, nous constatons également que lorsque plus des données sont relevés sur un plus grande de temps pour les variables cliniques, la performance du modèle augmente significativement sur les différentes tâches de prédiction.

Références

- Johnson, A. E., T. J. Pollard, L. Shen, L.-w. H. Lehman, M. Feng, M. Ghassemi, B. Moody, P. Szolovits, L. Anthony Celi, et R. G. Mark (2016). Mimic-iii, a freely accessible critical care database. *Scientific data* 3(1), 1–9.
- Rajkomar, A., E. Oren, K. Chen, A. M. Dai, N. Hajaj, M. Hardt, P. J. Liu, X. Liu, J. Marcus, M. Sun, et al. (2018). Scalable and accurate deep learning with electronic health records. *NPJ digital medicine* 1(1), 1–10.
- Song, H., D. Rajan, J. Thiagarajan, et A. Spanias (2018). Attend and diagnose : Clinical time series analysis using attention models. In *Proceedings of the AAAI conference on artificial intelligence*, Volume 32.