

Stratification automatique de l'insuffisance cardiaque à l'aide d'un réseau neuronal convolutif

Jad BOTROS¹, Farah MOURAD-CHEHADE¹, David LAPLANCHE^{1,2}

¹ Laboratoire Informatique et Société Numérique (LIST3N), Université de Technologie de Troyes (UTT)

 2 Pôle Santé publique, Hôpitaux Champagne Sud (HCS)

Correspondance: jad.botros@utt.fr

Abstract

L'insuffisance cardiaque (IC) survient lorsque le cœur est trop faible pour pomper suffisamment de sang dans les artères ou manque d'élasticité pour remplir les artères de manière adéquate. Il s'agit d'une maladie chronique et progressive qui, selon sa gravité, nécessite un diagnostic et un traitement rapides. L'IC est classée en quatre niveaux par le système de classification de la New York Heart Association (NYHA) sur la base des limitations physiques pendant l'activité physique. L'électrocardiogramme (ECG) est un test non invasif utilisé pour diagnostiquer l'IC en analysant les intervalles RR, la fréquence cardiaque ou la variabilité de la fréquence cardiaque (VFC). Ce papier décrit un modèle de réseau neuronal convolutif (CNN) profond à dix couches qui permet de déterminer automatiquement le stade de l'IC. Le modèle CNN proposé ne nécessite pas une extraction de caractéristiques et seulement un prétraitement minimal des signaux VFC. Le modèle est formé et testé sur un ensemble de données équilibrées extraites des bases de données des signaux des intervalles RR, et il atteint une précision de 95.33%, une sensibilité de 87.14% et une spécificité de 95.70%.

Keywords— Apprentissage profond, classification multi-classe, réseau neuronal convolutif, insuffisance cardiaque, classification de la New York Heart Association, signaux des intervalles RR.

1 Introduction

L'IC est un état pathologique dans lequel le cœur est incapable de générer un débit cardiaque suffisant pour répondre aux besoins métaboliques et recevoir un retour veineux, en raison de lésions cardiaques fonctionnelles ou structurelles causées par divers facteurs. L'exercice, le stress physique et mental, la respiration, la régulation de la pression artérielle et d'autres facteurs influencent tous la régularité du cœur, entraînant des intervalles variables entre les battements sinusaux normaux [1, 2, 3]. Le système nerveux autonome (SNA) régule le système cardio-vasculaire, ce qui est important dans divers contextes pathologiques, y compris l'IC. L'IC est typiquement associée à l'activation du système nerveux sympathique (SNS) et à l'inhibition du système nerveux parasympathique (SNP), ce qui entraîne des changements hémodynamiques et des altérations

Colloque JETSAN 2023



de la fonction cardiaque [4, 5]. La cause la plus courante de la VFC est la variation périodique, qui peut être analysée de manière non-invasive à l'aide d'enregistrements Holter pour fournir une mesure sensible de l'apport autonome au cœur [3]. La VFC est un outil bien connu d'évaluation de la modulation autonome cardiaque qui a été utilisé dans divers contextes cliniques, y compris l'IC [6, 7, 8, 9]. Après un diagnostic d'IC, les professionnels de la santé doivent rapidement déterminer la gravité de l'affection afin d'établir le meilleur plan de traitement [10]. Le système de classification fonctionnelle de la NYHA est la norme mondialement reconnue utilisée par les médecins pour évaluer la gravité de l'IC. La NYHA fournit une méthode simple pour évaluer la gravité de l'IC en classant les patients dans l'une des quatre catégories en fonction de leurs limitations d'activité physique [11]. Pour résoudre le problème de la stratification de l'IC ou de l'évaluation du risque, de nombreuses méthodes d'apprentissage automatique et d'apprentissage profond ont été proposées dans la littérature. Certains chercheurs, comme dans [12, 13, 14], ont utilisé des mesures de la VFC en conjonction avec l'arbre de classification et de régression (CART) ou des classifieurs à k plus proches voisins (kNN) pour faire la distinction entre l'IC légère et l'IC sévère. D'autres chercheurs ont utilisé un classifieur SVM basé sur un arbre de décision (DT-SVM) ou d'autres techniques d'apprentissage automatique tels que les arbres d'ensemble, algorithmes de prédiction séquentielle et autres pour classer les mesures de VFC dans les classes I, II et III de la NYHA, ou pour distinguer les individus sains des différentes classes de la NYHA [15, 16, 17, 18, 19, 20, 21]. Cependant, les méthodes traditionnelles d'apprentissage automatique nécessitent des efforts importants de préparation et d'exploration des données, tels que la mise en forme, le nettoyage et l'ingénierie des caractéristiques, qui peuvent prendre beaucoup de temps et nécessiter une main-d'œuvre importante

[22]. La qualité des données influe sur la capacité d'apprentissage du modèle, et la sélection des caractéristiques est une étape cruciale qui prend beaucoup de temps. Par rapport aux méthodes traditionnelles d'apprentissage automatique, diverses techniques d'apprentissage profond ont été utilisées pour améliorer la précision des systèmes de diagnostic assisté par ordinateur. Les auteurs de [23] et [24] ont utilisé des réseaux neuronaux convolutifs, des réseaux neuronaux récurrents (RNN) et des réseaux multi-résidus (Multi-ResNet) pour classer les signaux ECG dans les classes NYHA, avec des degrés de précision et de sensibilité variables.

La contribution du papier: Dans ce papier, un nouveau modèle d'apprentissage profond qui utilise un signal VFC à court terme pour classer les sujets comme normaux ou dans l'une des trois des quatre catégories de la NYHA est proposé. Ce modèle est basé sur un CNN à 10 couches qui détecte les caractéristiques significatives sans nécessiter d'intervention humaine. Le modèle proposé utilise l'apprentissage profond pour résoudre le problème de la classification multi-classes de l'IC selon la classification de la NYHA. Cette méthode est démontrée à l'aide de signaux de la VFC réels obtenus à partir de moniteurs Holter ambulatoires et de bases de données ECG. Le reste du document est organisé comme suit. La section 2 décrit la base de données et détaille le pré-traitement. La section 3 présente la méthode proposée. La section 4 présente et discute les résultats obtenus. Enfin, la section 5 présente la conclusion.

2 Matériel et Pré-traitement

2.1 Base de données

Les signaux d'intervalle RR dans cette étude rétrospective proviennent de deux bases de données disponibles au public: la base de données d'intervalles RR du rythme sinusal normal (NSR)



[25] et la base de données d'intervalles RR de l'insuffisance cardiaque congestive (CHF) [25]. La première base de données contient des signaux d'intervalles RR extraits de cinquante-quatre signaux ECG à long terme, de trente hommes en bonne santé âgés de 28,5 à 76 ans et de vingtquatre femmes en bonne santé âgées de 58 à 73 ans. La seconde base de données contient vingtneuf signaux d'intervalles R-R extraits de signaux ECG à long terme, de huit hommes, deux femmes et dix-neuf sujets non identifiés diagnostiqués avec une insuffisance cardiaque. Chaque enregistrement de la base de données est classé dans la classe I, II ou III, avec quatre patients classés dans la classe I, huit dans la classe II et dix-sept dans la classe III. La base de données a toutefois une limite : elle ne contient pas d'enregistrements pour les sujets de classe IV, ce qui limite la classification aux classes I-III de la NYHA. Les signaux ECG originaux sont échantillonnés à 128 Hz, avec 20 heures d'enregistrement. Les annotations des battements pour chaque signal sont générées par une analyse automatisée avec une révision et une correction manuelles, mais les signaux ECG originaux ne sont pas disponibles.

2.2 Pré-traitement

2.2.1 Filtrage

L'analyse de la VFC est plus précise lorsque l'on utilise des séries temporelles d'intervalles RR ne comportant que des battements sinusaux purs, également connus sous le nom d'intervalles NN. Les intervalles RR obtenus à partir d'enregistrements ECG ambulatoires, en revanche, sont souvent erronés en raison de battements ectopiques et d'artefacts [26]. Les séries temporelles d'intervalles RR plus longues peuvent également présenter une tendance de base de la fréquence [27]. Pour résoudre ce problème, les données relatives aux intervalles RR sont filtrées à l'aide du diagramme de Poincaré. Le diagramme de Poincaré est une

représentation graphique d'un vecteur x à N dimensions, où $x = (x_1, x_2, x_3, ... x_N)$. Il est formé par le tracé de deux vecteurs auxiliaires dérivés de x, x^+ et x^- . x^+ est défini comme $(x_1, x_2, x_3, ..., x_N - 1)$, et x^- est défini comme $(x_2, x_3, x_4, \dots x_N)$. Le diagramme de Poincaré est construit en traçant toutes les paires ordonnées (x_i^+, x_i^-) pour *i* allant de 1 à N-1. Le filtrage du diagramme de Poincaré est équivalent au filtrage des données. Les filtres d'annotation, de carré et de quotient sont utilisés en combinaison pour supprimer les battements ectopiques et le bruit du tracé de Poincaré. Le filtre d'annotation supprime les battements incorrects en les identifiant et en les supprimant dans les deux vecteurs auxiliaires. Pour les données non annotées, le filtre carré supprime les intervalles inférieurs à 300 ms ou supérieurs à 2000 ms. Le filtre quotient est le plus agressif, il supprime les battements et leurs contreparties si l'une des quatre conditions énumérées est remplie, mais il peut également laisser les battements incorrects non filtrés. Dans cette étude, les trois filtres sont utilisés simultanément [28]. Les ondelettes sont utilisées dans l'analyse des ondelettes pour détecter la tendance générale d'une série temporelle, qui correspond à la partie la plus lente du signal avec la valeur d'échelle la plus élevée. Une ondelette est utilisée pour décomposer la série temporelle en différents niveaux d'approximation et de détail, l'approximation de haut niveau fournissant la meilleure estimation de la tendance inconnue. L'analyse de l'ondelette db3 a déterminé que l'approximation de haut niveau a6 est une approximation raisonnable pour détecter la tendance inconnue, qui est alors approchée à l'aide de l'approximation de haut niveau. Cette méthode est utilisée dans l'étude pour éliminer la composante tendancielle des signaux [27].

2.2.2 Segmentation des données

Les signaux d'intervalles RR d'une durée de 20 heures sont divisés en formes d'onde individuelles,



chacune ayant une durée de 100 intervalles RR. Avant d'être introduits dans le réseau, ces signaux segmentés sont normalisés à l'aide de la normalisation du score Z, l'écart type étant fixé à 1 et la moyenne à 0. L'ensemble de données résultant contient 61278 segments de 100 intervalles RR chacun, extraits de 29 sujets normaux et 29 patients souffrant de l'IC, avec 3580 segments appartenant à la classe I de la NYHA, 8962 segments appartenant à la classe II de la NYHA et 17633 segments appartenant à la classe III de la NYHA.

2.2.3 Augmentation des données

Lorsqu'il y a trop peu d'exemples dans la classe minoritaire, la classification déséquilibrée peut être problématique car le modèle peut avoir du mal à apprendre la limite de décision de manière efficace. Le sur-échantillonnage des exemples de la classe minoritaire est une solution. L'augmentation des données peut contribuer à la création de nouveaux exemples issus de la population minoritaire. La technique de sur-échantillonnage synthétique des minorités (SMOTE) est une méthode populaire de création d'exemples synthétiques. Cette technique consiste à sélectionner des exemples proches les uns des autres dans l'espace des caractéristiques, à tracer une ligne entre eux et à tirer un nouvel échantillon en un point aléatoire le long de cette ligne. Un membre du groupe minoritaire est choisi au hasard et k de ses voisins les plus proches (généralement k=5) sont identifiés. Ensuite, un voisin est choisi au hasard et un exemple synthétique dans l'espace des caractéristiques est créé en un point aléatoire entre les deux. Ce processus peut être répété indéfiniment pour générer des exemples plausibles et proches de la classe minoritaire [29, 30]. Dans les étapes suivantes, la technique SMOTE sera utilisée pour augmenter l'ensemble de données pour la formation et le test du modèle.

3 Méthode

Cet article propose un CNN à 10 couches. L'un des principaux avantages du CNN par rapport aux algorithmes traditionnels d'apprentissage automatique est qu'il élimine la nécessité d'une ingénierie manuelle des caractéristiques et d'une réduction de la dimensionnalité qui prennent Les CNN sont conçus beaucoup de temps. pour extraire des caractéristiques significatives des données d'apprentissage et classer des données de haute dimension. Le modèle proposé se compose de quatre couches convolutives, de trois couches de max-pooling et de trois couches entièrement connectées. La première couche du réseau accepte un segment de 100 intervalles RR, qui est une matrice de nombres à une dimension, chaque nombre représentant le temps écoulé entre les pics R consécutifs. La fonction première du CNN est de réduire le vecteur en une forme plus facile à traiter tout en conservant les caractéristiques importantes pour une prédiction précise.

La première couche du réseau proposé est une couche convolutionnelle avec trente-deux filtres 13 qui sont appliqués avec un pas de un, ce qui permet d'obtenir trente-deux cartes de caractéristiques générées par la convolution des différents filtres avec le signal d'entrée de 100 points d'intervalles RR. Selon l'équation (1), les couches convolutionnelles effectuent la convolution de différents filtres avec le signal d'entrée.

$$Y_n = \sum_{k=0}^{N-1} x_k f_{n-k}, \qquad (1)$$

où Y est le résultat de la convolution du signal x par le noyau f, n et k sont des indices de position, et N est la taille du signal.

La deuxième couche est une autre couche convolutive avec soixante-quatre filtres 13 et un stirde de 1. La troisième couche est une couche de maxpooling avec deux pools et un stride de deux qui réduit les dimensions des cartes de caractéristiques.



Un taux de dropout de 0,3 est appliqué après cette couche. Il s'agit d'un masque qui annule la contribution de certains neurones à la couche suivante tout en laissant tous les autres non modifiés. Pour extraire des caractéristiques de plus haut niveau, la séquence convolution - max-pooling - dropout est répétée deux fois de plus avec 128 et 256 filtres dans les couches convolutionnelles, respectivement. Viennent ensuite trois couches entièrement connectées avec respectivement 256, 64 et 4 unités.

L'entrée initiale de la première couche est simplement une version aplatie de la sortie de la couche précédente. La structure du réseau proposé est illustrée à la Figure 1.

À l'exception de la dernière couche, qui utilise la fonction d'activation softmax, la fonction d'activation ReLU est utilisée pour toutes les autres couches.

Dans les modèles de classification multi-classes, la sortie de la couche dense finale est généralement un vecteur de probabilité qui attribue une probabilité à chaque classe, indiquant la probabilité qu'un échantillon appartienne à chaque classe. La fonction argmax est souvent utilisée pour convertir ce vecteur en étiquette de classe en sélectionnant l'indice ayant la probabilité la plus élevée [31]. Les poids du modèle sont initialisés à l'aide de l'initialisation uniforme de Glorot et mis à jour à l'aide de la rétro-propagation (back-propagation) avec une taille de lot de 128. Des couches de dropout avec un taux de dropout de 0.3 sont





utilisées pour éviter l'overfitting.

Soit y_i l'étiquette du segment *i* de l'ensemble de données d'apprentissage, c'est-à-dire $y_i = 0$ si le segment *i* est extrait d'un signal normal, $y_i = 1$ si le segment *i* est extrait d'un signal IC de classe I, $y_i = 2$ si le segment *i* est extrait d'un signal IC de classe II, et $y_i = 3$ si le segment *i* est extrait d'un signal IC de classe III.

La fonction d'entropie croisée catégorielle est utilisée dans le problème de la classification multiclasses pour déterminer la perte du modèle. L'équation utilisée à cette fin est démontrée comme suit :

$$\mathcal{L} = -\Sigma_{i=1}^{M} y_i \log(\hat{y}_i), \qquad (2)$$

où M est le nombre de valeurs scalaires dans la sortie du modèle (M = 4 dans ce cas), \hat{y}_i est la *i*-ième valeur scalaire dans la sortie du modèle, et y_i est la valeur cible correspondante, et la taille de la sortie est le nombre de valeurs scalaires dans la sortie du modèle. L'entropie croisée calcule un score qui représente la différence moyenne entre les valeurs réelles et les valeurs prédites. Le score doit être minimisé, la valeur 0 correspondant à une entropie croisée parfaite.

4 Résultats et discussion

Le modèle proposé est testé en effectuant une validation croisée stratifiée 10 fois sur un ensemble de données de 122 556 segments. L'ensemble de données est divisé en dix parties égales, chacune comportant une proportion égale de chaque classe. Le modèle est entraîné et validé dix fois, chaque itération comprenant neuf parties pour l'entraînement et une pour la validation. Trois mesures d'évaluation sont utilisées : la précision, la sensibilité et la spécificité. Les formules de ces mesures, qui utilisent les taux de vrais positifs (TP), de vrais négatifs (TN), de faux positifs (FP) et de faux négatifs (FN), sont énumérées dans le

Colloque JETSAN 2023



texte. La précision moyenne du modèle a été de 93.55%, avec une sensibilité moyenne de 87.14% et une spécificité de 95.70%. Après un nombre suffisant d'époques, la fonction de perte du modèle converge et atteint un minimum stable. Le code du modèle a été écrit en Python et mis en œuvre à l'aide de Google Colab.

Pour démontrer l'efficacité de la méthode proposée, ses résultats sont comparés à ceux obtenus par six méthodes de stratification de l'IC basées sur l'apprentissage automatique et profond et utilisant les mêmes bases de données.

Dans une méthode antérieure, décrite dans [13], les chercheurs ont d'abord choisi des patients dont le rapport Normal-Normal (NN) sur RR (NN/RR) était supérieur ou égal à 80%. La méthode de recherche exhaustive a ensuite été utilisée pour extraire treize caractéristiques des signaux VRC à long terme. Ces caractéristiques ont ensuite été introduites dans un classifieur CART, qui a été utilisé pour différencier les patients à faible risque (LRP, classes I et II de la NYHA) et les patients à haut risque (HRP, classes III et IV de la NYHA). La validation croisée a été utilisée pour évaluer les performances du classifieur, qui a atteint une précision de 85,4%, une sensibilité de 93,3% et une spécificité de 63,6% pour distinguer les patients à faible risque des patients à haut risque. Les auteurs de [14] ont choisi treize mesures de VRC à long terme après avoir éliminé les battements ectopiques à l'aide d'un filtre carré et d'un filtre quotient et après avoir éliminé l'errance de la ligne de base à l'aide d'une technique de détrition basée sur les ondelettes. Ces caractéristiques ont ensuite été introduites dans un classifieur kNN, qui a utilisé la validation croisée leave-one-out pour atteindre une précision inférieure à 50% dans la distinction entre les classes I, II et III de la NYHA. [15] décrit une méthode d'extraction des caractéristiques des signaux VRC à long terme à l'aide de la GDA et les introduit dans un classifieur kNN pour distinguer les PRL et les PRH. En utilisant la même

technique de validation, ce modèle a atteint une précision, une sensibilité et une spécificité de 100%. Après avoir prétraité les signaux, [16] a extrait 180 caractéristiques statiques et dynamiques des signaux VRC à court terme en utilisant l'algorithme d'élimination à rebours pour la sélection des caractéristiques. Ces caractéristiques ont ensuite été introduites dans un SVM non équilibré basé sur DT, qui a classé avec précision les patients atteints d'IC dans les classes I, II et III de la NYHA. Des mesures à court terme de la VRC ont été utilisées dans [20] pour évaluer les performances d'un SVM et d'un classifieur CART dans la classification de la gravité de l'IC. En utilisant la validation croisée 10 fois, les modèles ont atteint des précisions de 84%, 71,2% et 83,4%, et 81,4%, 66,8% et 81,6%. Une autre méthode décrite dans [21] utilise des mesures de VRC à long terme réduites à un classifieur 1-NN utilisant l'algorithme de sélection séquentielle. En utilisant la validation croisée leave-one-out, le modèle a atteint une précision de 87.80%, une sensibilité de 81,47% et une spécificité de 95,59% pour différencier entre les sujets normaux et les quatre classes de la NYHA.

Les résultats montrent que l'apprentissage profond avec une architecture appropriée, surpasse les méthodes existantes. Comparé aux méthodes traditionnelles d'apprentissage automatique, l'apprentissage profond permet une abstraction plus fiable du signal dans un espace à haute dimension sans nécessiter d'intervention humaine, ce qui se traduit par des performances plus élevées.

L'apprentissage profond a été utilisé dans [23, 24] pour mettre en scène l'IC à l'aide de fragments d'ECG de 2s et 5s. Ces méthodes ont été plus performantes que le modèle proposé en termes de sensibilité, mais au détriment de la spécificité et de la précision. Le modèle proposé comporte moins de couches que ces architectures de modèles profonds.



Conclusion 5

L'objectif de cette étude est de créer une méthode automatisée d'évaluation de la gravité du risque de l'IC selon le système de classification de la NYHA. Pour ce faire, une approche CNN à 10 couches entièrement automatisée est proposée, qui nécessite un pré-traitement minimal en raison de la nature bruvante des signaux d'intervalles RR humains et élimine le besoin de sélection des caractéristiques. Pour obtenir des enregistrements d'intervalles RR, les bases de données des intervalles RR du rythme sinusal normal et de l'IC congestive sont utilisée. Ces base de données sont facilement accessible sur Internet. Pour éviter les problèmes de déséquilibre des données, l'ensemble de données est constitué de 30175 segments d'intervalles RR de patients souffrant d'IC, puis augmenté par SMOTE. Le classifieur CNN proposé dans cet article a obtenu des mesures d'évaluation élevées, notamment une précision de 93.55%, une sensibilité de 87.14% et une spécificité de 95.70%. Ces résultats indiquent que cette méthode peut jouer un rôle crucial dans l'évaluation de la gravité de l'IC chez les patients. Les travaux futurs pourraient inclure l'incorporation des signaux des intervalles RR de la classe IV de la NYHA afin d'améliorer la précision du suivi des patients au fil du temps.

References

- [1] Heart Failure. (2022),https://www.nhlbi.nih.gov/health/heart-failure, Accessed on October 31, 2022
- [2] Heart Failure: Compensation by (2022),the Heart and Body. Accessed on October 31, 2022
- [3] Stein, P., Bosner, M., Kleiger, R. & Conger, B. Heart rate variability: a measure of cardiac autonomic tone. American Heart Journal. 127, 1376-1381 (1994)

- [4] Kishi, T. Heart failure as an autonomic nervous system dysfunction. Journal Of Cardiology. 59, 117-122 (2012)
- [5] Florea, V. & Cohn, J. The autonomic nervous system and heart failure. Circulation Research. 114, 1815-1826(2014)
- [6] Sztajzel, J. & Others Heart rate variability: a noninvasive electrocardiographic method to measure the autonomic nervous system. Swiss Medical Weekly. 134, 514-522 (2004)
- [7] Ravenswaaij-Arts, C., Kollee, L., Hopman, J., Stoelinga, G. & Geijn, H. Heart rate variability. Annals Of Internal Medicine. 118, 436-447 (1993)
- [8] Luczak, H. & Laurig, W. An analysis of heart rate variability. Ergonomics. 16, 85-97 (1973)
- [9] Malik, M. Heart rate variability. Current Opinion In Cardiology. 13, 36-44 (1998)
- [10] Bennett, J., Riegel, B., Bittner, V. & Nichols, J. Validity and reliability of the NYHA classes for measuring research outcomes in patients with cardiac disease. Heart Lung. 31, 262-270 (2002)
- [11] Specifications Manual Joint Commisfor Quality Measures. (2018),sion National https://manual.jointcommission.org/releases/TJC2018A/DataEle Accessed on October 31, 2022
- [12] Pecchia, L., Melillo, P. & Bracale, M. Remote health monitoring of heart failure with data mining via CART method on HRV features. IEEE Transactions On Biomedical Engineering. 58, 800-804 (2010)
- [13] Melillo, P., De Luca, N., Bracale, M. & Pecchia, L. Classification tree for risk assessment in patients suffering from congestive heart failure via long-term heart rate variability. IEEE Journal Of Biomedical And Health Informatics. 17, 727-733 (2013)
- https://myhealth.alberta.ca/Health/Pages/conditions.asjtx?h&idamaa86963.Eklund, M. Automated classification of congestive heart failure severity using time domain, frequency domain and non-linear heart rate variability measures. Proceedings Of The 25th Annual International Conference On Computer Science And Software Engineering. pp. 46-52 (2015)

Colloque JETSAN 2023



- [15] Shahbazi, F. & Asl, B. Generalized discriminant analysis for congestive heart failure risk assessment based on long-term heart rate variability. *Computer Methods And Programs In Biomedicine.* **122**, 191-198 (2015)
- [16] Chen, W., Zheng, L., Li, K., Wang, Q., Liu, G. & Jiang, Q. A novel and effective method for congestive heart failure detection and quantification using dynamic heart rate variability measurement. *PloS One.* **11**, e0165304 (2016)
- [17] Bou Rjeily, C., Badr, G., Al Hassani, A. & Andres, E. Predicting heart failure class using a sequence prediction algorithm. 2017 Fourth International Conference On Advances In Biomedical Engineering (ICABME). pp. 1-4 (2017)
- [18] Tripoliti, E., Papadopoulos, T., Karanasiou, G., Kalatzis, F., Bechlioulis, A., Goletsis, Y., Naka, K. & Fotiadis, D. Estimation of New York Heart Association class in heart failure patients based on machine learning techniques. 2017 IEEE EMBS International Conference On Biomedical Health Informatics (BHI). pp. 421-424 (2017)
- [19] Ma, S., Zhang, R., Munroe, J., Shanahan, L., Horn, S. & Speedie, S. Estimating New York Heart Association Classification for Heart Failure Patients from Information in the Electronic Health Record. 2018 IEEE International Conference On Bioinformatics And Biomedicine (BIBM). pp. 1504-1507 (2018)
- [20] Qu, Z., Liu, Q. & Liu, C. Classification of congestive heart failure with different New York Heart Association functional classes based on heart rate variability indices and machine learning. *Expert Systems.* 36, e12396 (2019)
- [21] Hua, Z., Chen, C., Zhang, R., Liu, G. & Wen, W. Diagnosing various severity levels of congestive heart failure based on long-term HRV signal. *Applied Sci*ences. 9, 2544 (2019)
- [22] Asgher, U., Khalil, K., Ayaz, Y., Ahmad, R. & Khan, M. Classification of mental workload (MWL) using support vector machines (SVM) and convolutional neural networks (CNN). 2020 3rd International Conference On Computing, Mathematics And Engineering Technologies (iCoMET). pp. 1-6 (2020)
- [23] Li, D., Li, X., Zhao, J. & Bai, X. Automatic staging model of heart failure based on deep learning.

Biomedical Signal Processing And Control. **52** pp. 77-83 (2019)

- [24] Li, D., Tao, Y., Zhao, J. & Wu, H. Classification of congestive heart failure from ECG segments with a multi-scale residual network. *Symmetry.* 12, 2019 (2020)
- [25] Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P., Mark, R., Mietus, J., Moody, G., Peng, C. & Stanley, H. PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *Circulation.* **101**, e215e220 (2000)
- [26] Peltola, M. Role of editing of R-R intervals in the analysis of heart rate variability. *Frontiers In Physiol*ogy. 3 pp. 148 (2012)
- [27] Thuraisingham, R. Preprocessing RR interval time series for heart rate variability analysis and estimates of standard deviation of RR intervals. *Computer Meth*ods And Programs In Biomedicine. 83, 78-82 (2006)
- [28] Jarosław, P. & Przemysław, G. Filtering poincare plots. CMST. 11, 39-48 (2005)
- [29] Chawla, N., Bowyer, K., Hall, L. & Kegelmeyer, W. SMOTE: synthetic minority over-sampling technique. *Journal Of Artificial Intelligence Research.* 16 pp. 321-357 (2002)
- [30] Brownlee, J. SMOTE for imbalanced classification with python. (2020,1), https://machinelearningmastery.com/smoteoversampling-for-imbalanced-classification/ Accessed on: Oct. 31, 2022
- [31] Brownlee, J. What is argmax in machine learning?. (2020), https://machinelearningmastery.com/argmax-inmachine-learning/, Accessed on October 31, 2022

Colloque JETSAN 2023