

Détection automatique des pics d'un signal de pression intracrânienne : comparaison d'algorithmes combinant apprentissage profond et fonction de courbure

D. Legé^{1,2}, M. Prud'homme², J. Henriot²

¹ Sophysa, France

² Université de Bourgogne-Franche-Comté, CNRS, FEMTO-ST, DISC, 25030 Besançon, France

dlege@sophysa.com

Résumé

La pression intracrânienne d'un patient en unité de soins intensifs peut être monitorée en continu. Le signal obtenu contient des pulsations d'origine cardiaque sur lesquelles apparaissent des pics de pression. Cet article décrit une étude préliminaire à la détection automatique des pics P1 et P2, dont les amplitudes relatives sont caractéristiques de la compliance cérébrale du patient. Les algorithmes proposés combinent une recherche d'extrema locaux au résultat d'une classification binaire effectuée par des réseaux de neurones. Les modèles comparés contiennent des blocs récurrents et/ou convolutifs.

Mots-clés

Pression intracrânienne, compliance cérébrale, CNN, LSTM

Abstract

The intracranial pressure signal of a patient in an intensive care unit can be monitored continuously. The resulting signal contains pulses of cardiac origin on which pressure peaks appear. This paper describes a preliminary study for the automated detection of P1 and P2 peaks, whose relative amplitudes are characteristic of the patient's brain compliance. The proposed algorithms combine a local extrema search with the result of a binary classification performed by neural networks. The models compared contain recursive and/or convolutional blocks.

Keywords

Intracranial pressure, Cerebral compliance, CNN, LSTM

1 Introduction

La Pression Intracrânienne (PIC) est une grandeur biologique classiquement monitorée invasivement en unité de soins intensifs lors d'atteintes cérébrales. L'un des principaux objectifs du clinicien est de limiter le temps passé par le patient au-dessus d'un seuil d'hypertension cérébrale [4]. Cependant, le signal obtenu est un mélange complexe de différentes composantes périodiques, d'origine respiratoire et cardiaque. La PIC moyenne seule ne capture donc pas

toute l'information offerte par ce monitoring sur l'état du patient [7]. En particulier, le signal de PIC permettrait de décrire la capacité du système cérébrospinal à encaisser des changements de volume dus aux déplacements de sang et de liquide cérébrospinal (LCS) sans endurer une trop forte augmentation de PIC [10]. Cette relation pression-volume, généralement désignée par le terme de compliance cérébrale, est fastidieuse à mesurer directement à partir de tests de perfusion de LCS [17]. C'est pourquoi différentes caractérisations de la compliance cérébrale ont été proposées directement à partir de l'analyse de la courbe de PIC [6][21]. En particulier, la forme des pulsations observées à l'échelle du cycle cardiaque varie avec la compliance cérébrale du patient. Dans des conditions normales, les pulsations comportent généralement trois pics d'amplitudes décroissantes, appelés P1, P2, P3 d'après leur ordre d'apparition. S'il est communément admis que P1 correspond à l'arrivée du volume systolique [5], les origines de P2 et P3 sont encore débattues. Des mesures au moyen d'imagerie à résonance magnétique (IRM) tendent à associer P2 à un maximum de volume dans les artères cérébrales [22]. L'origine de P3, longtemps interprétée comme le reflet de l'onde dicrote, pourrait être liée au retour veineux [13]. Au fur et à mesure que la compliance se dégrade, P2 devient de plus en plus grand devant P1 [3] jusqu'à ne former qu'une pulsation triangulaire. Le ratio des amplitudes relatives P1/P2 ($r_{1/2}$) a donc été proposé comme indicateur de la compliance cérébrale [16][2]. De plus, une bonne corrélation a été démontrée entre cette mesure et les valeurs de compliance obtenues par des tests de perfusion [14]. Des exemples de formes de pulsations cardiaques sont présentés figure 1.

1.1 Travaux antérieurs

Un algorithme d'analyse de la courbe de PIC, incluant découpage des pulsations, suppression du bruit et détection automatique des pics P1, P2 et P3 a été proposé sous la dénomination MOCAIP (Morphological Clustering and Analysis of Continuous Intracranial Pressure) [11]. La détection des pics était originellement effectuée à partir de distributions gaussiennes estimées sur la base de pulsations annotées. Les auteurs de l'algorithme MOCAIP en ont pro-




FIGURE 1 – Exemples de formes de pulsations cardiaques avec (A) un ratio $r_{1/2} < 1$ et (B) un ratio $r_{1/2} > 1$.

posé différentes améliorations, la dernière en date utilisant un réseau bayésien dynamique [20]. De notre connaissance, il s’agit de la seule méthodologie de traitement complète du signal de PIC aboutissant à une détection des pics P1 et P2. Cependant, les différents algorithmes sont difficilement reproductibles, d’une part car ceux-ci reposent sur une base de données privée et d’autre part car peu d’indications sur l’implémentation des algorithmes sont fournies dans les différents articles. De plus, l’algorithme nécessite l’acquisition d’un électrocardiogramme (ECG) en parallèle de la PIC, ce qui peut poser des difficultés d’un point de vue pratique. Sur des problématiques voisines, différentes approches impliquant des réseaux de neurones ont été proposées pour la détection de pics des ECG, des réseaux convolutifs [12] aux réseaux récurrents [9]. Des architectures semblables ont également été utilisées pour classer les pulsations cardiaques de la courbe de PIC sur la base de leur forme générale, en s’affranchissant cette fois de la détection de pics en particulier [19] [18]. Les classes retenues vont de 1 (saine) à 4 (pathologique), la dernière classe étant réservée aux artefacts. Toutefois, cet indicateur n’étant pas continu, des problèmes d’interprétation peuvent se poser pour les intermédiaires se situant entre deux classes.

1.2 Problématique

Les présents travaux constituent une étude préliminaire à la mise en place d’un algorithme de détection automatique des pics P1 et P2, l’objectif final étant de calculer en temps réel le ratio de leurs amplitudes relatives à partir d’un monitoring de PIC. Celles-ci sont évaluées uniquement sur des pulsations où les pics P1 et P2 sont identifiables, ce qui représente 80 à 90% des pulsations observées sur des monitorages réels [20]. À terme, l’algorithme retenu sera donc précédé d’une phase de sélection des pulsations au ratio $r_{1/2}$ calculable. Les processus de prétraitements, les deux algorithmes de détection proposés ainsi que les différentes architectures de réseaux de neurones associées sont décrits section 2. La section 3 présente le processus expérimental ainsi que les résultats obtenus. Enfin, la section 4 offre des pistes de réflexion autour de la méthode de détection des pics P1 et P2 dans son ensemble.

2 Méthodologie

2.1 Collecte et annotations des données

2.1.1 Acquisition des signaux de PIC

Les signaux de PIC étudiés proviennent de 7 patients atteints de traumatisme crânien ayant été admis en réanimation au CHU de Saint-Étienne, France, entre mars et juillet 2022. Pour chacun d’entre eux, la PIC a été monitorée invasivement au moyen d’un capteur intraparenchymateux (Pressio, Sophysa, Orsay, France) pour une durée de 8.34 ± 5 jours (min = 3.8, max = 15) à une fréquence d’échantillonnage de 100Hz.

Pour chaque patient, 5 segments d’une heure ont été extraits à des temps aléatoires du monitoring. 4 d’entre eux ont été affectés au jeu d’entraînement, et 1 au jeu de test.

2.1.2 Prétraitements

Un filtre passe-bande entre 0.3 et 10 Hz est appliqué au signal de PIC. Les pulsations cardiaques sont ensuite délimitées au moyen de l’algorithme de Scholkmann modifié [1] implémenté en C. L’amplitude de chaque pulsation est normalisée linéairement entre 0 et 1, et sa longueur est ramenée à 180 points au moyen d’une extrapolation polynomiale cubique. Ces prétraitements de la courbe de PIC sont semblables à ceux employés dans les travaux de Mataczynski *et al.* [18], à ceci près qu’un filtrage des fréquences inférieures à 0.3 Hz a été ajouté de façon à éliminer les oscillations physiologiques lentes, notamment dues à la respiration du patient.

2.1.3 Constitution de la base de données annotée

Après étude de différents exemples de référence avec les neuroréanimateurs du CHU de St-Etienne, les positions des pics P1 et P2 sont annotées manuellement, lorsque ceux-ci sont identifiables, par un seul auteur (D.L.). Dans le cas contraire, la pulsation est écartée de la base de données. Au total, 16 000 pulsations ainsi extraites sont utilisées pour l’entraînement des réseaux de neurones, et 4 000 pulsations sont conservées comme jeu de test.

2.2 Processus d’analyse

Les différentes analyses présentées ci-dessous ont été développées en Python 3.10. Leur implémentation est disponible à l’adresse suivante : https://github.com/donatien-lege/P1_P2_detection

2.2.1 Identification des pics P1 et P2

L’identification des pics P1 et P2 se fait en deux étapes : en premier lieu, un score entre 0 et 1 est affecté à chacun des points de la pulsation de façon à identifier les zones où les pics P1 et P2 ont de fortes chances d’être présents. Dans un second temps, une identification de leurs positions précises est effectuée par des critères d’analyse de fonctions.

Calcul du score. Les modèles d’intelligence artificielle sont entraînés pour une tâche de classification binaire : l’objectif est d’affecter à chacun des 180 points du vecteur d’entrée une valeur entre 0 et 1, tel qu’une valeur proche de 1 signifie que le point se situe proche d’un pic P1 ou P2. Pour

ce faire, les annotations (p_1, p_2) où p_1 et p_2 désignent respectivement les positions des pics P1 et P2 sont associés à des vecteurs de 180 points par la fonction ϕ telle que :

$$\phi : (p_1, p_2) \rightarrow l_{p_1}(\llbracket 1, 180 \rrbracket) + l_{p_2}(\llbracket 1, 180 \rrbracket)$$

où l_μ désigne la fonction $l_\mu : x \rightarrow e^{-|x-\mu|}$.

La tâche de classification consiste à trouver une fonction $f : [0, 1]^{180} \rightarrow [0, 1]^{180}$ telle que

$$f = \operatorname{argmin} \left(\frac{1}{N} \sum_{i=1}^N CE(f(x_i), \phi(y_i)) \right)$$

Où CE désigne la *cross-entropy*, utilisée comme fonction de perte, et où x, y désignent respectivement les exemples et les annotations de la base de données de taille N .

Identification des pics P1 et P2. Une première stratégie, reposant uniquement sur la fonction de score f estimée par un modèle de réseau de neurones, consiste à prendre comme \hat{p}_1 et \hat{p}_2 les deux plus grands maxima locaux de f . Comme \hat{f} peut présenter des maxima locaux correspondant au même pic (voir l'estimation de P1 sur la figure 2), et que la distance minimale observée entre les positions de P1 et P2 sur tout le jeu d'entraînement est de 10 points, le choix est fait de ne considérer que les maxima locaux supérieurs à tous les autres dans un voisinage de 5 points.

Une seconde méthode fait intervenir la courbure de la pulsation telle qu'utilisée par l'algorithme MOCAIP [11]. Pour une pulsation p , la courbure κ est définie par le ratio

$$\kappa(p) = \frac{p''}{(1 + p'^2)^{3/2}}$$

Pour chaque pulsation p , on pose $P = -100p$. Les pics \hat{p}_1 et \hat{p}_2 sont alors identifiés aux maxima locaux de $\kappa^*(P)$ correspondant aux deux plus grandes valeurs du produit $f(p) * \kappa^*(P)$, où κ^* désigne la fonction

$$\kappa^* = \max\left(0, \frac{\kappa}{\max(\kappa)}\right)$$

Un schéma des courbes obtenues au moyen des deux algorithmes, avec l'exemple d'un perceptron multicouche (Multi-layer Perceptron, MLP), est présenté sur la figure 2 pour une même pulsation p .

2.3 Réseaux de neurones utilisés

Les trois architectures de réseaux de neurones suivantes ont été sélectionnées pour leur succès d'utilisation pour des tâches similaires [23][8][18] :

- Un réseau de neurones convolutif (*Convolutional Neural Network*, CNN). Cette architecture extrait de l'information du voisinage de chaque point considéré au moyen d'un produit de convolution. Ce type de réseau de neurones est classiquement utilisé pour des traitements similaires sur d'autres signaux biologiques, comme les ECG [23][8]. Le CNN implémenté est constitué de trois blocs d'encodage (convolution - batch normalisation - activation ReLU) suivis par deux couches denses. Un




FIGURE 2 – Comparaison de deux algorithmes de détection des pics P1 et P2 sur une même pulsation p . MLP : pics P1 et P2 identifiés aux deux plus grand maxima locaux du score $f(p)$ calculé par un MLP entraîné. κ -MLP : P1 et P2 identifiés parmi les maxima locaux de la fonction de courbure normalisée $\kappa^*(P)$. Les deux pics retenus correspondent aux deux maxima locaux correspondant aux deux plus grandes valeurs du produit $f(p) * \kappa^*(P)$.

dropout de probabilité 0.1 est appliqué avant la dernière couche dense de façon à réduire le sur-apprentissage.

- Un réseau de neurones récurrent bidirectionnel à mémoire court et long terme (*Bidirectional Long Short-Term Memory*, Bi-LSTM). Cette architecture a pour propriété de modéliser les dépendances à court et long terme d'une information séquentielle, comme une série temporelle. Cette capacité à capturer l'information liée à la succession des pics est d'autant plus pertinente que ces derniers sont davantage identifiés par leur succession (P1 et P2 précèdent nécessairement un P3) que par leur forme, qui peut être très variable. Le réseau implémenté est constitué d'une cellule Bi-LSTM suivie d'un dropout appliqué avec une probabilité de 0.1 et d'une couche dense.
- Une combinaison des deux architectures précédentes (*Long Short-Term Memory Fully Convolutional Network*, LSTM-FCN). Le réseau implémenté est constitué de trois blocs d'encodage en parallèle d'une cellule bi-LSTM. Les deux sorties sont concaténées puis synthétisées au moyen d'une couche dense. Ce type d'architecture a notamment obtenu de bons résultats pour une tâche de classification de pulsations de PIC [18].

En tant que référence, un perceptron multicouche (*Multi-Layer Perceptron*, MLP) à trois couches denses cachées est également comparé aux trois réseaux de neurones présentés ci-dessus. Le détail des métaparamètres et des dimensions des différents réseaux utilisés sont présentés en annexe.

Pour chacune des architectures, une fonction sigmoïde est appliquée au vecteur de sortie avant le calcul de la fonction de perte, de façon à ramener toutes les valeurs entre 0 et 1.

3 Résultats

3.1 Entraînement et évaluation des modèles

3.1.1 Processus d'entraînement

Un pipeline d'analyse est implémenté au moyen de Snakemake 7.25.0 [15]. L'utilisation d'un tel gestionnaire de *workflow* présente différents avantages, comme améliorer la reproductibilité des analyses, et faciliter l'exploration parallélisée des différentes combinaisons de méthodes présentées section 2.2.1. Ce dernier est constitué des étapes suivantes :

- Entraînement des modèles. Ceux-ci sont réalisés avec des métaparamètres fixés, soit une taille de batch de 32, un taux d'apprentissage initial de 0.001, et un nombre d'époques fixé à 200. Dans les deux cas, une descente de gradient est effectuée avec l'optimiseur ADAM de façon à minimiser la *cross-entropy*.
- Calcul de la courbure normalisée κ^* des pulsations du jeu de test.
- Identification des pics sur le jeu de test par les 8 méthodes considérées, correspondant aux quatre architectures associées ou non à la courbure des pulsations.
- Calcul des erreurs obtenues. La tâche d'identification des pics P1 et P2 fait l'objet d'une évaluation sur l'erreur moyenne du ratio P1/P2, mais également sur la capacité des modèles à séparer les pulsations avec un ratio P1/P2 inférieur ou supérieur à 1. Les métriques et les résultats obtenus sont détaillés section 3.1.2.

3.1.2 Métriques utilisées

Pour chaque méthode de détection des pics P1 et P2, on calcule l'erreur moyenne absolue *MAE* sur les amplitudes relatives des pics *P1* et *P2* pour les *M* exemples de test :

$$MAE = \frac{1}{M} \sum_{i=1}^M |r_{1/2}(\hat{i}) - r_{1/2}(i)|$$

La matrice de confusion des classes "+" : " $r_{1/2} > 1$ " et "-" : " $r_{1/2} \leq 1$ " est également calculée, de façon à en déduire les taux de faux positifs *FP*, faux négatifs *FN*, et de prédictions correctes *Acc*.

3.2 Performances obtenues

Les performances obtenues pour les 8 méthodes de détection sont présentées dans le tableau 1. Les méthodes prenant en compte la fonction de courbure κ présentent globalement des performances supérieures à leurs équivalents uniquement basés sur les sorties des réseaux de neurones. En particulier, la prise en compte de la courbure occasionne un gain moyen de 6% de l'*Acc* calculée.

Les proportions de chacun des cinq clusters parmi les pulsations mal classées par le bi-LSTM et le par le CNN sont comparées table 2.

De façon à comparer les erreurs de classification obtenues par les réseaux convolutifs et les réseaux récurrents, une analyse en composantes principales (ACP) est effectuée sur les 284 pulsations du jeu de test mal classées par le réseau récurrent bi-LSTM et/ou par le CNN, associés à la fonction de courbure. Un clustering est effectué au moyen d'un algorithme des *k* moyennes (*k-means*) où *k* est fixé à 5 après inspection visuelle des deux premières composantes principales. Les pulsations moyennes correspondantes sont présentées figure 3.




FIGURE 3 – Représentation des des premières composantes principales des pulsations mal classées par le CNN et/ou le réseau récurrent bi-LSTM, associés à la fonction de courbure. Les couleurs correspondent aux clusters obtenus par l'algorithme des *k*-means. Les pulsations affichées correspondent aux pulsations moyennes de chaque cluster.

4 Discussion

L'objectif de cette étude est d'évaluer les apports potentiels de modèles à base de réseaux de neurones pour l'analyse automatique des pulsations d'origine cardiaque sur la courbe de PIC. Les méthodes de prétraitements et de découpage des pulsations étant bien décrites dans la littérature, le problème peut être réduit à l'analyse de courtes séries temporelles - environ une seconde pour un échantillonnage à 100 Hz. Cette légèreté calculatoire bénéficie à des architectures de réseaux de neurones relativement simples, la plus performante parmi les candidats étant ici constituée d'une unique cellule bi-LSTM. Un MLP à trois couches cachées, à l'origine utilisé comme ligne de base, dépasse en *accuracy* des architectures plus complexes utilisant plusieurs blocs d'encodage. Lors du regroupement des pulsations mal classées en 5 clusters par l'algorithme des *k*-means, on observe une répartition relativement homogène des erreurs par le réseau récurrent, tandis que près de la moitié des erreurs du CNN sont dues à des pulsations du cluster 0. Ces pulsations peuvent présenter un léger pic juste avant l'élévation

	hz_P1 (%)	hz_P2 (%)	vt_P1 (%)	vt_P2 (%)	MAE_ratio	FP (%)	FN (%)	Acc (%)
κ -MLP	0.86 ± 0.08	1.68 ± 0.14	1.7 ± 0.3	1.5 ± 0.2	0.08 ± 0.06	4.0	2.6	96.6
MLP	2.42 ± 0.09	3.47 ± 0.12	5.7 ± 0.5	3.3 ± 0.2	0.090 ± 0.006	18.4	3.0	88.5
κ -bi-LSTM	0.67 ± 0.06	0.89 ± 0.07	1.0 ± 0.2	0.6 ± 0.1	0.019 ± 0.003	1.7	3.1	97.7
bi-LSTM	1.16 ± 0.06	1.78 ± 0.08	1.7 ± 0.2	0.7 ± 0.1	0.035 ± 0.003	4.9	2.3	96.3
κ -CNN	1.01 ± 0.09	1.30 ± 0.10	3.1 ± 0.5	1.2 ± 0.2	0.461 ± 0.005	6.3	2.6	95.3
CNN	2.60 ± 0.11	3.90 ± 0.13	8.1 ± 0.6	3.3 ± 0.2	0.111 ± 0.006	24.9	6.0	83.6
κ -LSTM-FCN	0.90 ± 0.09	1.33 ± 0.11	2.6 ± 0.4	1.2 ± 0.2	0.06 ± 0.04	5.2	2.3	96.1
LSTM-FCN	1.77 ± 0.11	3.13 ± 0.16	4.7 ± 0.5	2.5 ± 0.2	0.786 ± 0.006	12.1	2.7	92.1

TABLE 1 – Performances de 4 architectures de réseaux de neurones pour la détection des pics P1 et P2, associées ou non à la fonction de courbure κ . MAE_{P1} : Erreur moyenne absolue sur l’amplitude relative du pic P1. MAE_{P2} : Erreur moyenne absolue sur l’amplitude relative du pic P2. FP , FN , Acc : Proportion de faux positifs, faux négatifs et de prédictions correctes pour la classe "+" : " P1/P2 > 1". les incertitudes affichées correspondent à un intervalle de confiance à 95%.

cluster	0	1	2	3	4
bi-LSTM	25.2%	26.3%	26.8%	11.2%	10.2%
CNN	48.6%	20.4%	6.1%	8.3%	16.6%

TABLE 2 – Répartition des pulsations mal classées par le bi-LSTM (n=89) et par le CNN (n=180) parmi les 5 clusters identifiés.

brutale de PIC correspondant au véritable P1, que le réseau convolutif identifie alors à P1 par erreur. Le succès du réseau récuratif peut donc être dû à la nécessité de prendre en compte toute la séquence des pics candidats pour identifier P1 et P2. Contrairement à l’analyse d’ECG, dont le signal comporte des événements à la forme bien identifiable comme un complexe QRS, les pics P1 et P2 recherchés ont des formes beaucoup plus variables, et doivent nécessairement être suivis d’un pic P3 pour être identifiés.

La tâche de détection effectuée ici aurait pu être vue comme un problème de régression; les positions des pics P1 et P2 auraient alors été directement prédites par les réseaux de neurones. Le choix du score continu, qui nécessite toutefois la définition d’une fonction d’annotation ϕ , a été fait d’une part pour sa robustesse aux prédictions aberrantes, et d’une autre pour les possibilités de combinaison offertes avec la fonction de courbure. L’association avec cette analyse mathématique simple de la pulsation améliore de plus l’explicitabilité des prédictions, tout en offrant des garanties sur les capacités de généralisation. Cela est d’autant que plus important que le faible nombre de patients constitue la principale limite aux travaux présentés. Les métriques utilisées ont été choisies en regard de l’interprétation clinique la plus fréquente : un $r_{1/2} < 1$ est considéré comme un signe d’une compliance cérébrale dégradée. Juger des performances sur cette classification binaire semble donc approprié; une troisième classe où P1 \approx P2 pourrait être définie, mais poserait alors la question des valeurs limites.

5 Conclusion

Les présents travaux exploitent l’association entre intelligence artificielle et calculs de dérivées pour la détection automatique des pics P1 et P2 sur le signal de PIC. Les

performances des algorithmes envisagées ont été comparées sur un jeu de test de 4 344 pulsations, avec comme critères la MAE sur l’amplitude relative des pics P1 et P2 et la capacité d’identification des pulsations de $r_{1/2} < 1$. L’algorithme présentant les meilleures performances sur le jeu de test étudié combine une fonction de courbure au résultat d’une tâche de classification binaire par un réseau de neurones comportant une cellule bi-LSTM. Les méthodes présentées peuvent encore être améliorées par un travail sur la fonction d’annotation ϕ , une *fine-tuning* des modèles de réseaux de neurones présentés et un élargissement des jeux de test et d’entraînement à davantage de patients. Plus généralement, la problématique traitée présente deux difficultés majeures que sont (i) la variabilité intra- et interpatient dans la forme des pulsations et (ii) la potentielle absence de ces pics, pour des raisons physiologiques ou artéfactuelles. Les méthodes présentées ici ne se concentrant que sur les cas où les pulsations P1 et P2 sont effectivement visibles, celles-ci doivent être précédées une première étape d’élimination des pulsations sans ratio calculable.

Remerciements

Les auteurs remercient le Dr. Laurent GERGELÉ (CHU de St-Étienne) ainsi que le Dr. Yoann LAUNEY (CHU de Rennes) pour leurs conseils avisés sur l’interprétation médicale du signal de PIC. Les auteurs remercient l’Association Nationale de la Recherche et de la Technologie (ANRT) pour le financement du dispositif CIFRE mis en place avec Sophsya.

Références

- [1] Steven M Bishop and Ari Ercole. Multi-scale peak and trough detection optimised for periodic and quasi-periodic neuroscience data. In *Intracranial Pressure & Neuromonitoring XVI*, pages 189–195. Springer, 2018.
- [2] Sérgio Brasil, Davi Jorge Fontoura Solla, Ricardo de Carvalho Nogueira, Manoel Jacobsen Teixeira, Luiz Marcelo Sá Malbouisson, and Wellingson Silva Paiva. Intracranial compliance assessed by intra-

- cranial pressure pulse waveform. *Brain Sciences*, 11(8) :971, 2021.
- [3] Erico R Cardoso, Jack O Rowan, and Sam Galbraith. Analysis of the cerebrospinal fluid pulse wave in intracranial pressure. *Journal of neurosurgery*, 59(5) :817–821, 1983.
- [4] Nancy Carney, Annette M Totten, Cindy O’Reilly, Jamie S Ullman, Gregory WJ Hawryluk, Michael J Bell, Susan L Bratton, Randall Chesnut, Odette A Harris, Niranjana Kissoon, et al. Guidelines for the management of severe traumatic brain injury. *Neurosurgery*, 80(1) :6–15, 2017.
- [5] Emmanuel Carrera, Dong-Joo Kim, Gianluca Castellani, Christian Zweifel, Zofia Czosnyka, Magdalena Kasprowicz, Peter Smielewski, John D Pickard, and Marek Czosnyka. What shapes pulse amplitude of intracranial pressure? *Journal of neurotrauma*, 27(2) :317–324, 2010.
- [6] Marek Czosnyka and John D Pickard. Monitoring and interpretation of intracranial pressure. *Journal of Neurology, Neurosurgery & Psychiatry*, 75(6) :813–821, 2004.
- [7] Marek Czosnyka, Peter Smielewski, Ivan Timofeev, Andrea Lavinio, Eric Guazzo, Peter Hutchinson, and John D Pickard. Intracranial pressure : more than a number. *Neurosurgical focus*, 22(5) :1–7, 2007.
- [8] Lahcen El Bouny, Mohammed Khalil, and Abdelilah Adib. Ecg heartbeats classification based on 1-d convolutional neural networks. In *Advanced Intelligent Systems for Sustainable Development (AI2SD’2020) Volume 1*, pages 697–708. Springer, 2022.
- [9] Andoni Elola, Elisabete Aramendi, Unai Irusta, Artzai Picón, Erik Alonso, Pamela Owens, and Ahamed Idris. Deep neural networks for ecg-based pulse detection during out-of-hospital cardiac arrest. *Entropy*, 21(3) :305, 2019.
- [10] Karin Germon. Interpretation of icp pulse waves to determine intracerebral compliance. *The Journal of neuroscience nursing : journal of the American Association of Neuroscience Nurses*, 20(6) :344–351, 1988.
- [11] Xiao Hu, Peng Xu, Fabien Scalzo, Paul Vespa, and Marvin Bergsneider. Morphological clustering and analysis of continuous intracranial pressure. *IEEE Transactions on Biomedical Engineering*, 56(3) :696–705, 2008.
- [12] Jaeseong Jang, Seongjae Park, Jin-Kook Kim, Junho An, and Sunghoon Jung. Cnn-based two step r peak detection method : Combining segmentation and regression. In *2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, pages 1910–1914. IEEE, 2022.
- [13] Magdalena Kasprowicz, Marvin Bergsneider, Marek Czosnyka, and Xiao Hu. *Association between ICP pulse waveform morphology and ICP B waves*. Springer, 2012.
- [14] Agnieszka Kazimierska, Magdalena Kasprowicz, Marek Czosnyka, Michał M Placek, Olivier Baledent, Peter Smielewski, and Zofia Czosnyka. Compliance of the cerebrospinal space : Comparison of three methods. *Acta neurochirurgica*, 163 :1979–1989, 2021.
- [15] Johannes Köster and Sven Rahmann. Snakemake—a scalable bioinformatics workflow engine. *Bioinformatics*, 28(19) :2520–2522, 2012.
- [16] Shinken Kuramoto, Kazuhiko Moritaka, Takashi Hayashi, Eiichiro Honda, and Takao Shojima. Non-invasive measurement in intracranial pressure and analysis of the pulse waveform. *Neurological Research*, 8(2) :93–96, 1986.
- [17] Anthony Marmarou, Kenneth Shulman, and Roberto M Rosende. A nonlinear analysis of the cerebrospinal fluid system and intracranial pressure dynamics. *Journal of neurosurgery*, 48(3) :332–344, 1978.
- [18] Cyprian Mataczyński, Agnieszka Kazimierska, Agnieszka Uryga, Małgorzata Burzyńska, Andrzej Rusiecki, and Magdalena Kasprowicz. End-to-end automatic morphological classification of intracranial pressure pulse waveforms using deep learning. *IEEE Journal of Biomedical and Health Informatics*, 26(2) :494–504, 2021.
- [19] Carlotta Ginevra Nucci, Pasquale De Bonis, Annunziato Mangiola, Pietro Santini, Marco Sciandrone, Arnaldo Risi, and Carmelo Anile. Intracranial pressure wave morphological classification : automated analysis and clinical validation. *Acta neurochirurgica*, 158 :581–588, 2016.
- [20] Paria Rashidinejad, Xiao Hu, and Stuart Russell. Patient-adaptable intracranial pressure morphology analysis using a probabilistic model-based approach. *Physiological measurement*, 41(10) :104003, 2020.
- [21] Andreas Spiegelberg, Matthias Krause, Juergen Meixensberger, and Vartan Kurtcuoglu. Raq : a novel surrogate for the craniospinal pressure–volume relationship. *Physiological Measurement*, 41(9) :094002, 2020.
- [22] Mårten Unnerbäck, Johnny T Ottesen, and Peter Reinstrup. Icp curve morphology and intracranial flow-volume changes : a simultaneous icp and cine phase contrast mri study in humans. *Acta Neurochirurgica*, 160 :219–224, 2018.
- [23] Muhammad Uzair Zahid, Serkan Kiranyaz, Turker Ince, Ozer Can Devecioglu, Muhammad EH Chowdhury, Amith Khandakar, Anas Tahir, and Moncef Gabbouj. Robust r-peak detection in low-quality holter ecgs using 1d convolutional neural network. *IEEE Transactions on Biomedical Engineering*, 69(1) :119–128, 2021.