



HAL
open science

Étude comparative de modèles de clustering de séries temporelles multivariées issues d'objets médicaux connectés

Violaine Courier, Christophe Biernacki, Cristian Preda, Benjamin Vittrant

► **To cite this version:**

Violaine Courier, Christophe Biernacki, Cristian Preda, Benjamin Vittrant. Étude comparative de modèles de clustering de séries temporelles multivariées issues d'objets médicaux connectés. EGC 2024 - 24ème Conférence Francophone sur l'Extraction et Gestion des Connaissances, Jan 2024, Dijon, France. pasteur-04364645v1

HAL Id: pasteur-04364645

<https://riip.hal.science/pasteur-04364645v1>

Submitted on 27 Dec 2023 (v1), last revised 9 Jan 2024 (v2)

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Distributed under a Creative Commons Attribution 4.0 International License

Étude comparative de modèles de clustering de séries temporelles multivariées issues d'objets médicaux connectés

Violaine Courrier*, Christophe Biernacki**, Cristian Preda**, Benjamin Vittrant***

* Inria, Univ. Lille / Withings, v.courrier@yahoo.fr

**Inria, Univ. Lille, christophe.biernacki@inria.fr, cristian.preda@inria.fr

*** Withings, benjamin.vittrant@withings.com

Résumé. Dans le domaine de la santé, les données des patients sont souvent collectées sous forme de séries temporelles multivariées, offrant une vue complète de l'état de santé d'un patient au fil du temps. Ces données sont généralement éparses et épisodiques. Cependant, les objets médicaux connectés peuvent augmenter la fréquence des données. L'objectif est de créer de manière non supervisée des profils de patients à partir de ces séries temporelles. En l'absence de labels, un modèle prédictif peut être utilisé pour prédire les valeurs futures tout en formant un espace de clusters latents, évalué en fonction de la performance prédictive. À l'aide des données réelles de l'entreprise Withings, nous comparons les approches de clustering statique MAGMACLUST, qui crée un cluster à l'échelle de toute la série temporelle, et de clustering dynamique DGM², qui permet à l'appartenance d'un individu à un groupe de changer avec le temps.

1 Introduction

Dans le domaine de la santé, les données des patients sont souvent recueillies sous forme de séries temporelles multivariées (MTS, pour Multidimensional Time Series). Cela signifie que plusieurs paramètres sont mesurés à différents moments pour chaque patient (sa tension artérielle, sa fréquence cardiaque, son poids, etc.). Ces données sont extrêmement précieuses car elles permettent de suivre l'évolution de l'état de santé d'un patient dans le temps et de détecter des indicateurs d'une maladie ou d'un risque de maladie. Une contrainte majeure réside dans la sparsité de ces données. En effet, le patient n'est que rarement à l'hôpital (pour des examens par exemple), ce qui signifie que les mesures enregistrées relatives à sa santé sont essentiellement épisodiques. Cependant, des objets médicaux connectés offrent un suivi à domicile du patient, ce qui permet d'augmenter la fréquence des mesures. Ces mesures à domicile ne sont en revanche pas toujours réalisées dans des conditions contrôlées, ce qui peut affecter leur fiabilité.

Le grand apport des séries temporelles multivariées, en plus de la dimension temporelle, est le caractère multivarié qui offre une vue plus complète et plus précise de l'état de santé d'un patient. En analysant plusieurs variables simultanément, cela permet d'utiliser les effets de corrélation et de causalité entre différentes variables, des informations qui seraient perdues

dans une analyse univariée. Cela peut aider à identifier des facteurs de risque ou des signes précoces de maladie qui pourraient être manqués autrement.

2 Clustering de séries temporelles multivariées

L'objectif est de créer des profils patients à partir de séries temporelles multivariées qui illustrent leur état de santé. Une particularité de ces données est l'absence de labels. Par exemple, un patient atteint d'hypertension ne le précise pas au moment de sa prise de tension ou bien lors de sa pesée. Son état de santé est a priori inconnu, et il s'agit de le déterminer. Cela revient alors à créer des groupes de patients de façon non supervisée. Un intérêt de ces clusters est de faire de la prévention, en ciblant par exemple les individus d'un cluster où l'incidence d'une maladie est significativement plus élevée.

2.1 Etat de l'art

Le clustering de séries temporelles est un sujet majeur. Une revue de la littérature par Aghabozorgi et al. (2015) identifie 3 catégories de méthodes : le "clustering de séries temporelles entières", le "clustering de sous-séquences" et le "clustering de points temporels". Selon Jacques et Preda (2013), il y a quatre familles de modèles de clustering au niveau de la série temporelle entière.

La première famille traite les séries temporelles comme des entités de haute dimension, en négligeant leur nature temporelle, une approche qui peut être illustrée par les travaux de Biernacki et Maugis (2015). La seconde stratégie adopte une démarche en deux temps : une réduction de dimension initiale, par des techniques telles que l'Analyse en Composantes Principales (ACP), suivie d'un clustering classique. La troisième famille repose sur des approches non paramétriques, qui privilégient l'utilisation de mesures de distance ou de dissimilarité spécifiques aux séries temporelles, telles que la distance de Dynamic Time Warping (DTW), pour ensuite appliquer des algorithmes de clustering traditionnels adaptés aux données de dimension finie (exemple donné par Gullo et al. (2012)). La dernière catégorie englobe les méthodes qui supposent une distribution de probabilité sous-jacente aux données, souvent mises en œuvre via des modèles génératifs ou des techniques de clustering basées sur des mélanges de distributions.

Les développements récents dans ce domaine incluent l'intégration du deep learning (par exemple l'article de Ma et al. (2019)), qui ouvrent de nouvelles perspectives pour le clustering de séries temporelles de grande dimension.

2.2 Comparaison DGM2 et MagmaClust

Dans le contexte où les données ne sont pas labellisées, nous proposons d'utiliser un modèle prédictif qui génère un espace de clustering latent. Ce modèle positionne les individus ayant des caractéristiques similaires dans le même groupe et exploite ces informations pour améliorer la précision de la prédiction. L'utilisation d'un modèle prédictif offre l'avantage

d'évaluer la qualité du clustering en se basant sur la performance prédictive du modèle, mesurée par des indicateurs tels que l'erreur quadratique moyenne (RMSE) ou l'erreur absolue moyenne (MAE). Nous partons du principe qu'un clustering plus précis et pertinent fournit des informations supplémentaires qui améliorent la capacité de prédiction du modèle.

Nous présentons deux méthodes de clustering distinctes : la première réalise un clustering de la série temporelle dans son intégralité, tandis que la seconde adopte une approche de clustering dynamique, attribuant un cluster unique à chaque instant temporel. Ces deux méthodes sont basées sur des modèles gaussiens : l'un utilise des processus gaussiens dans une modélisation bayésienne tandis que l'autre repose sur une distribution de mélange gaussien. L'adoption d'une base gaussienne pour ces modèles nous intéresse pour sa flexibilité et sa capacité à capturer des structures sous-jacentes des données.

Dans la suite, on notera X_i la série temporelle multivariée d'un individu i , avec $X_i = X_{i,1:T} = (X_{i,1}, \dots, X_{i,T})$, où $X_{i,t} = (X_{i,t}^1, \dots, X_{i,t}^d)$ avec $X_{i,t}^j$ la valeur de la variable j de l'individu i au temps t , $\forall j = 1, \dots, d$, $t = 1, \dots, T$.

2.3 Clustering statique de séries entières

En partant de l'hypothèse d'existence d'une structure de groupe dans les données, nous proposons d'utiliser l'extension d'un modèle de prédiction (MAGMA, Leroy et al. (2022)). Ce modèle introduit une étape de clustering à K groupes à l'aide d'un mélange de processus gaussiens (GP, pour Gaussian Process) (MAGMACLUST de Leroy et al. (2023))¹. Ce modèle utilise plusieurs processus gaussiens pour modéliser la moyenne des données. Le modèle génératif proposé se définit alors pour le cluster k , $k = 1, \dots, K$, comme suit :

$$X_{i,t} = \mu_{k,t} + f_{i,t} + \epsilon_{i,t}, \forall i, \forall t \in \{1, \dots, T\}$$

avec

- $\mu_{k,t}$ le GP moyen spécifique au k -ème groupe,
- $f_{i,t}$ le GP spécifique à l'individu i ,
- $\epsilon_{i,t}$ le GP du bruit spécifique à l'individu i .

Cette modélisation correspond à un modèle mixte avec la moyenne du groupe comme effet fixe et l'effet sujet et l'erreur en effets aléatoires. Des hypothèses d'indépendance entre ces processus sont considérées.

Pour illustrer le modèle, la Figure 1 montre une prédiction pour le cluster le plus probable (ici le cluster 1 parmi $K = 3$ classes) à partir de données synthétiques.

2.4 Clustering dynamique

Au vu de l'historique d'enregistrement des mesures qui peut être long, et puisque l'état de santé du patient évolue dans le temps, il est souhaitable que l'appartenance d'un individu à un groupe puisse également évoluer dans le temps. Le clustering par intervalle de temps serait un

1. <https://github.com/ArthurLeroy/MagmaClustR>

Étude comparative de modèles de clustering de séries temporelles




FIG. 1 – Courbes de prédiction (violet) avec les intervalles de crédibilité à 95 % associés (rose) de MAGMACLUST. Les lignes en pointillé représentent les moyennes des estimations des processus moyens. Les points de données observés sont en noir, les points de données de test sont en rouge. Les points en arrière plans sont les observations de l'ensemble des données d'apprentissage, colorées par rapport à leur appartenance à un cluster. "Input" correspond aux pas de temps et "Output" à la valeur de la variable.

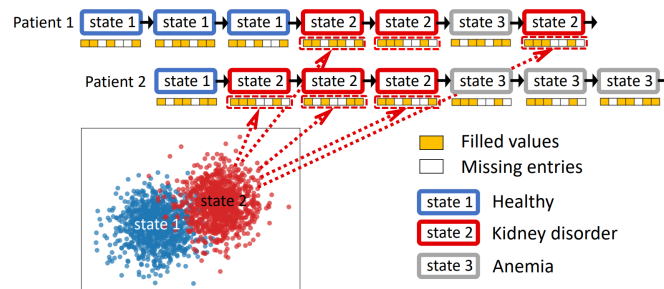


FIG. 2 – Illustration de clustering dynamique des MTS éparées de deux patients dialysés. Le vecteur sous chaque état est une caractéristique temporelle générée à partir d'une certaine distribution.

candidat (modèles 'interval-based') mais il nécessite de définir le début et la fin de la séquence d'intérêt. On s'intéresserait plutôt dans notre cas à classifier par pas de temps, et donc à faire ce qu'on appellera ici du clustering dynamique, c'est-à-dire que l'appartenance d'un individu à un cluster est indexée par le temps.

Par exemple, considérons les MTS collectés pour les patients en dialyse. La dialyse est une thérapie de remplacement rénal importante pour purifier le sang des patients dont les reins ne fonctionnent pas normalement. Les patients en dialyse ont des routines qui entraînent la collecte d'un nombre varié de signaux. Un modèle qui associe un état de santé à chaque pas de temps, comme illustré dans la Figure 2, pourrait aider les professionnels de la santé à détecter rapidement les changements significatifs dans l'état du patient.

Le clustering dynamique suppose l'existence d'un processus qualitatif latent à K modali-

tés, $Z = \{Z_t, t \in [0, T]\}$, avec $Z_t \in \{1, \dots, K\}$. Ainsi, à chaque série $X_{i,t}$, on associe la trajectoire qualitative définissant le groupe du patient i , $z_{i,t} \in \{1, \dots, K\}$.

Le modèle DGM² de Wu et al. (2021)² permet de faire ce clustering dynamique. C'est un modèle génératif qui suit la transition des clusters latents afin d'obtenir une modélisation robuste. Ce modèle se distingue par une distribution de mélange gaussien dynamique, qui saisit la dynamique des structures de clustering. Les auteurs introduisent un modèle génératif qui capture les structures latentes de regroupement dynamique pour des prévisions robustes. Il suit le cadre de transition et d'émission suivant :

1. Probabilité de transition : la probabilité d'un nouvel état $z_{i,t+1}$ est mise à jour en fonction des états précédents $z_{i,1:t} = (z_{i,1}, \dots, z_{i,t})$, c'est-à-dire

$$p(z_{i,t+1}|z_{i,1:t}) = \text{softmax}(MLP(h_{i,t})),$$

avec $h_{i,t} = RNN(z_{i,t}, h_{i,t-1})$.

MLP représente un perceptron multicouche (Multilayer Perceptron) et RNN des réseaux neuronaux récurrents (Recurrent Neural Networks).

2. Tirer $z_{i,t+1}$ d'une distribution catégorielle sur toutes les composantes du mélange c'est-à-dire $z_{i,t+1} \sim \mathcal{M}(p(z_{i,t+1}|z_{i,1:t}))$.
3. Tirer $\tilde{z}_{i,t+1}$ du mélange de distribution gaussiennes dynamique c'est-à-dire $\tilde{z}_{i,t+1} \sim \mathcal{M}(\psi_{i,t+1})$ (voir l'annexe A.2 pour le détail de $\psi_{i,t+1}$).
4. Tirer $\tilde{x}_{i,t+1}$ à partir de la distribution gaussienne du cluster auquel appartient $\tilde{z}_{i,t+1}$.

$z_{i,t+1}$ est utilisé dans la transition (étape 1) pour maintenir la propriété récurrente ; $\tilde{z}_{i,t+1}$ est utilisé dans l'émission (étape 4).

Pour approcher la distribution a posteriori, paramétrée par des réseaux de neurones avec des paramètres ϕ , on utilise le modèle d'inférence suivant :

$$q_\phi(z_{t+1}|x_{1:t+1}, z_t) = \text{softmax}(MLP(\tilde{h}_{t+1})),$$

avec $\tilde{h}_{t+1} = RNN(x_t, \tilde{h}_t)$.

Dans notre expérience, les deux RNNs sont des LSTMs (Long Short-Term Memory, introduit par Hochreiter et Schmidhuber (1997)).

3 Comparaison des performances

3.1 Présentation des données

Pour comparer les deux modèles précédents, nous considérons les données de l'entreprise Withings³. Withings est une entreprise qui conçoit des objets médicaux connectés tels que des montres, des balances ou encore des tensionnètres.

2. <https://github.com/thuwuyinjun/DGM2>

3. <https://www.withings.com/fr/fr/>

Étude comparative de modèles de clustering de séries temporelles

Nous avons créé un dataset de données agrégées par mois pour l'année 2022. Les utilisateurs ont de 18 à 100 ans, et possèdent une balance et un sleep analyzer⁴. Nous nous intéressons à 2 variables : *BMI* (la moyenne par mois du BMI⁵), et *Sleep* (la moyenne par mois de la durée de sommeil). Nous avons établi des critères selon lesquels une nuit de sommeil doit durer entre 45 minutes et 20 heures, et le BMI d'un individu doit se situer entre 10 et 65.

Nous sélectionnons 3 jeux de données, pour lesquels nous utilisons 10 mois consécutifs d'historique pour prédire les 2 prochains mois (voir l'annexe A.1 pour les statistiques descriptives des datasets) :

- Univarié :
 - un dataset de *BMI* de 60 individus
 - un dataset de *BMI* de 14 416 individus
- Multivarié : un dataset de *BMI* et de *Sleep* de 14 416 individus

Toutes les données sont standardisées⁶, ce qui permet de favoriser la comparaison des deux variables qui n'ont pas la même échelle de mesure. Nous utilisons les mêmes individus dans tous les jeux de données de test, ce qui donne une taille constante de 18 individus pour notre ensemble de test, représentant 30% de notre plus petit dataset.

Pour évaluer ces deux modèles, nous nous intéressons particulièrement au temps d'entraînement et aux performances prédictives (RMSE et MAE).

Pour pouvoir interpréter les performances de nos modèles, nous évaluons aussi 3 prédicteurs naïfs :

1. LAST VALUE : les prédictions prennent la valeur de la dernière observation
2. MEAN : les prédictions prennent la valeur de la moyenne des observations
3. MEDIAN : les prédictions prennent la valeur de la médiane des observations

Nous n'avons pas pour objectif d'analyser la réactivité des modèles face à la sparsité des séries temporelles, ainsi les jeux de données que nous utilisons n'ont pas de données manquantes.

Les deux modèles sont évalués sur la machine suivante (pas d'utilisation de GPU) : AMD Ryzen 7 pro 5850u avec radeon graphics × 16, Ubuntu Linux 22.04.

3.2 Analyse des séries univariées

Petit dataset Malgré leur bonne performance en prédiction, les modèles naïfs ne nous aident pas à regrouper les données en clusters, ce qui est notre but. Nous les utilisons pour avoir un point de comparaison pour évaluer la performance de nos modèles. Par ailleurs, puisque *BMI* est une variable plutôt stable, nous observons dans le Tableau 1 que l'estimateur naïf LAST VALUE a de très bonnes performances.

4. Un appareil placé sous le matelas qui permet de récupérer des informations sur la nuit de l'utilisateur.

5. $BMI = \text{poids}[\text{kg}] / \text{taille}^2[\text{m}^2]$

6. La standardisation ajuste la distribution d'une série temporelle en utilisant la moyenne et l'écart type du dataset d'entraînement, appliquant ensuite ces paramètres au dataset de test : $x_{standardise} = (x - \text{moyenne}) / \text{ecart-type}$.

LAST VALUE		MEAN		MEDIAN	
RMSE	MAE	RMSE	MAE	RMSE	MAE
0.0608	0.0557	0.6439	0.6425	0.6252	0.6229

TAB. 1 – Résultats des modèles naïfs sur un dataset univarié de 60 individus.

k	MAGMACLUST			DGM ²		
	RMSE	MAE	Time	RMSE	MAE	Time
3	0.8061	0.7344	1 min 53	0.6693	0.4643	4 sec
5	0.8767	0.7890	2 min 32	0.6967	0.4721	4 sec
7	0.8016	0.7275	2 min 27	0.6400	0.4580	4 sec
10	0.8019	0.7274	3 min 37	0.7219	0.4995	4 sec

TAB. 2 – Résultats des deux modèles comparés sur un dataset univarié de 60 individus.

Le Tableau 2 montre que sur un petit dataset univarié, DGM² a de meilleures performances que MAGMACLUST (en moyenne 0.14 d'écart RMSE et 0.27 MAE), bien que ces résultats soient inférieurs à ceux des estimateurs naïfs. Nous remarquons par ailleurs que DGM² est bien plus rapide, résultat prévisible puisque MAGMACLUST utilise un algorithme Variationnel Espérance-Maximisation (VEM) de complexité $\mathcal{O}(M \times N^3 + K \times N^3)$, avec M le nombre d'individus, N le nombre de points de temps et K le nombre de clusters.

LAST VALUE		MEAN		MEDIAN	
RMSE	MAE	RMSE	MAE	RMSE	MAE
0.0675	0.0611	0.7025	0.7006	0.7039	0.7023

TAB. 3 – Résultats des modèles naïfs sur un dataset univarié de 14 416 individus.

k	MAGMACLUST			DGM ²		
	RMSE	MAE	Time	RMSE	MAE	Time
3	0.8100	0.7589	14h58	0.4219	0.3477	9 min 76
5	0.6690	0.6008	13h08	0.2995	0.2295	10 min 63
7	0.6732	0.6041	19h22	0.2743	0.2126	11 min 05
10	0.6734	0.6201	27h18	0.2068	0.1590	11 min 54

TAB. 4 – Résultats des deux modèles comparés sur un dataset univarié de 14 416 individus.

Grand dataset Nous constatons dans le Tableau 4 que MAGMACLUST gagne légèrement en performance, et la durée nécessaire pour l'entraînement sur un dataset de cette taille est notable. Une forte amélioration des performances du modèle DGM² est visible avec notre dataset d'entraînement plus grand (gain de 0.4332 de RMSE et 0.299 de MAE en prenant les modèles avec les meilleures performances pour chaque dataset). Cette progression souligne l'efficacité de ce modèle à saisir la structure latente des clusters lorsqu'il a appris sur suffisamment de données, ce qui se traduit par des prédictions nettement plus précises par rapport à celles issues des modèles prédictifs naïfs MEAN et MEDIAN visibles dans le Tableau 3.

3.3 Analyse étendue au cadre multivarié

MAGMACLUST ne prend pas en compte la possibilité de prédire plusieurs dimensions. Nous testons donc seulement les performance de DGM² sur notre dataset multivarié.

	RMSE BMI	MAE BMI	RMSE Sleep	MAE Sleep
LAST VALUE	0.0675	0.0610	0.7983	0.7141
MEAN	0.7024	0.7006	0.9872	0.9259
MEDIAN	0.7038	0.7022	0.9794	0.9179

TAB. 5 – Résultats des modèles naïfs sur un dataset multivarié de 14 416 individus.

On constate dans le Tableau 5 que sur une variable moins stable que le *BMI* comme la variable *Sleep*, le prédicteur naïf LAST VALUE est moins performant.

k	Temps	RMSE	MAE	RMSE BMI	MAE BMI	RMSE Sleep	MAE Sleep
3	4 sec	0.7872	0.5963	0.6007	0.7234	0.9372	0.8181
5	4 sec	0.7408	0.5576	0.4398	0.6108	0.9510	0.8615
7	4 sec	0.7268	0.4759	0.4082	0.5301	0.9433	0.8190
10	4 sec	0.6239	0.4230	0.3075	0.4735	0.8269	0.7885

TAB. 6 – Résultats des deux modèles comparés sur un dataset multivarié de 14 416 individus.

Dans le cas multivarié, dont les résultats sont visibles dans le Tableau 6, les prédictions sont plus précises par rapport à celles issues de modèles prédictifs naïfs, mais avec le nombre de clusters fixé, l’ajout de la variable *Sleep* a impacté négativement les performances de prédiction de la variable *BMI*. Cette diminution de précision s’explique par la nécessité pour l’espace de clustering latent de prendre en compte les deux variables et leurs interactions, ce qui est une tâche plus complexe et le nombre de clusters nécessaire pour assurer une bonne prédiction augmente.

4 Conclusion

Le clustering dynamique pour suivre l’évolution de l’état d’un patient est pertinent dans notre cadre d’application, permettant de saisir des variations subtiles et des changements progressifs dans les données temporelles, offrant une perspective plus détaillée de la santé du patient. Le modèle DGM² se distingue par sa capacité à identifier ces clusters dynamiques, par ses performances prédictives et sa rapidité d’entraînement par rapport à MAGMACLUST.

Cependant, choisir le nombre approprié de clusters est un défi, car un nombre plus élevé rend l’interprétation plus complexe, tandis qu’un nombre insuffisant peut masquer des informations intéressantes, simplifiant excessivement la dynamique des données. Il est donc crucial de trouver un équilibre entre la décomposition détaillée des données et la facilité d’interprétation clinique. Trop de clusters peuvent nuire à l’analyse des tendances et à la prise de décision,

alors qu'un nombre insuffisant peut ignorer des aspects importants de l'évolution du patient.

Bien que DGM² présente des avantages significatifs pour le clustering prédictif en suivi patient, la détermination du nombre optimal de clusters demeure un enjeu important. Il est essentiel d'équilibrer le nombre de clusters avec leur pertinence clinique pour maintenir l'utilité de l'approche dans les décisions de soins de santé.

Références

- Aghabozorgi, S., A. Seyed Shirshorshidi, et T. Ying Wah (2015). Time-series clustering – a decade review. *Information Systems* 53, 16–38.
- Biernacki, C. et C. Maugis (2015). High-dimensional clustering. In *Choix de modèles et agrégation, Sous la direction de J-J. Droesbeke, G. Saporta, C. Thomas-Agnan*.
- Gullo, F., G. Ponti, A. Tagarelli, G. Tradigo, et P. Veltri (2012). A time series approach for clustering mass spectrometry data. *Journal of Computational Science* 3.
- Hochreiter, S. et J. Schmidhuber (1997). Long Short-Term Memory. *Neural Computation* 9(8), 1735–1780.
- Jacques, J. et C. Preda (2013). Functional data clustering : A survey. *Advances in Data Analysis and Classification* 8, 231–255.
- Leroy, A., P. Latouche, B. Guedj, et S. Gey (2022). MAGMA : inference and prediction using multi-task gaussian processes with common mean. *Machine Learning* 111(5), 1821–1849.
- Leroy, A., P. Latouche, B. Guedj, et S. Gey (2023). Cluster-specific predictions with multi-task gaussian processes. *Journal of Machine Learning Research* 24(5), 1–49.
- Ma, Q., J. Zheng, S. Li, et G. W. Cottrell (2019). Learning representations for time series clustering. In H. Wallach, H. Larochelle, A. Beygelzimer, F. d'Alché-Buc, E. Fox, et R. Garnett (Eds.), *Advances in Neural Information Processing Systems*, Volume 32. Curran Associates, Inc.
- Wu, Y., J. Ni, W. Cheng, B. Zong, D. Song, Z. Chen, Y. Liu, X. Zhang, H. Chen, et S. B. Davidson (2021). Dynamic gaussian mixture based deep generative model for robust forecasting on sparse multivariate time series. *CoRR abs/2103.02164*.

A Annexe

A.1 Description des données

Petit dataset Le dataset de 60 individus. Il y a 85% d'hommes (51) et 15% de femmes (9). La distribution de l'âge est exposé dans l'histogramme sur la Figure 3. La distribution des valeurs de la variable *BMI* des individus du petit dataset est visible sur la Figure 4.




FIG. 3 – Histogramme des âges des individus du petit dataset.




FIG. 4 – Histogramme des valeurs de *BMI* des individus du petit dataset.

Grand dataset Le dataset de 14 416 individus. Il y a 84,86% d’hommes (12 233) et 15,14% de femmes (2 182). La distribution des âges est exposée sur la Figure 5. La distribution de la variable *BMI* des individus du grand dataset est visible sur la Figure 6 et celle de la variable *Sleep* sur la Figure 7.




FIG. 5 – Histogramme des âges des individus du grand dataset.




FIG. 6 – Histogramme des valeurs de *BMI* des individus du grand dataset.




FIG. 7 – Histogramme des valeurs de *Sleep* des individus du grand dataset.

A.2 Description du mélange de distribution gaussiennes dynamique

Soit μ_k , avec $k = \{1, \dots, K\}$, la moyenne de la k -ème composante du mélange gaussien (statique), et soit $p(\mu_k)$ sa probabilité correspondante. Soit $p(\mu) = [p(\mu_1), \dots, p(\mu_K)] \in \mathbb{R}^K$.

Étude comparative de modèles de clustering de séries temporelles




FIG. 8 – Ajustement dynamique du mélange gaussien selon l'équation (1), avec 2 composantes.

On utilise (dans l'étape 3) le mélange de distribution dynamique suivant :

$$\psi_{i,t+1} = (1 - \gamma)p(z_{i,t+1}|z_{i,1:t}) + \gamma p(\mu) \quad (1)$$

avec $\gamma \in [0, 1]$ un hyperparamètre qui contrôle le degré relatif de changement par rapport à la distribution de mélange statique. La Figure 8 illustre ce processus.

Summary

In healthcare, patient data is often collected as multivariate time series, providing a comprehensive view of a patient's health status over time. While this data can be sparse, connected devices may enhance its frequency. The goal is to create patient profiles from these time series. In the absence of labels, a predictive model can be used to predict future values while forming a latent cluster space, evaluated based on predictive performance. We compare two models on Withing's datasets, MAGMACLUST which clusters entire time series and DGM² which allows the group affiliation of an individual to change over time (dynamic clustering).