



HAL
open science

Représentation explicable du comportement de systèmes complexes : automates pour les séries temporelles multivariées

Ikram Chraibi Kaadoud, Lina Fahed, Tian Tian, Yannis Haralambous,
Philippe Lenca

► To cite this version:

Ikram Chraibi Kaadoud, Lina Fahed, Tian Tian, Yannis Haralambous, Philippe Lenca. Représentation explicable du comportement de systèmes complexes : automates pour les séries temporelles multivariées. 7ème Conférence Nationale sur les Applications Pratiques de l'Intelligence Artificielle APIA @ PFIA 2022, Jun 2022, Saint-Etienne, France. hal-03811733

HAL Id: hal-03811733

<https://hal.science/hal-03811733>

Submitted on 12 Oct 2022

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.

Représentation explicable du comportement de systèmes complexes : automates pour les séries temporelles multivariées

I. Chraïbi Kaadoud^{1*} L. Fahed¹ T. Tian¹ Y. Haralambous¹ P. Lenca¹
¹IMT Atlantique, Lab-STICC, UMR CNRS 6285, Brest, France

{ikram.chraïbi-kaadoud, lina.fahed, tian.tian, yannis.haralambous, philippe.lenca}@imt-atlantique.fr

Résumé

La compréhension des états de systèmes complexes représentés par des séries temporelles peut être une tâche ardue, notamment à cause des changements permanents des événements contextuels internes et externes aux systèmes. Pour faire face à ce défi, nous proposons la méthode XR-CSB (eXplainable Representation of Complex System Behavior) dont l'objectif est de représenter l'évolution de tels systèmes d'une manière intelligible et explicable reposant sur : (i) un clustering vertical afin de détecter les états du système, (ii) une représentation visuelle explicable utilisant des automates dépliés, (iii) une pré-modélisation explicable fondée sur des métriques explicatives. Quatre représentations, évaluées par des experts du domaine applicatif de notre travail, montrent que XR-CSB passe à l'échelle et répond à leurs attentes en termes d'explicabilité et d'intelligibilité.

Mots-clés

Séries temporelles multivariées, représentation, explicabilité, automate, système complexe

Abstract

Understanding the states of complex systems represented by time series can be a difficult task, especially because of the constant changes in contextual events internal and external to the systems. To face this challenge, we propose the method XR-CSB, eXplainable Representation of Complex System Behavior, whose objective is to represent the evolution of such systems in an intelligible and explainable way based on : (i) a vertical clustering in order to detect the states of the system, (ii) an explainable visual representation using unfolded automata (iii) an explainable pre-modeling based on explainable metrics. Four representations, evaluated by experts in the application domain of our work, show that XR-CSB scales up and meets their expectations in terms of explainability and intelligibility.

Keywords

Multivariate time series, representation, explainability, finite-state automata, complex system

1 Introduction

Dans de nombreux cas d'applications, telles que l'énergie, le trafic urbain, etc., des systèmes de plus en plus complexes sont développés et utilisés [4]. Un système complexe peut être décrit par un ensemble important d'entités/variables interagissant dans le temps [11, 8]. Il est ainsi généralement représenté par des séries temporelles multivariées, où chaque série représente une variable du système dont les intervalles de valeurs correspondent à des états pour l'intervalle de temps associé [12].

Extraire des connaissances de ces systèmes et notamment leur évolution, est un défi lié aux changements permanents des événements contextuels internes et externes aux systèmes. Il est alors difficile de déterminer quelles sont les caractéristiques pertinentes qui contribuent à un changement d'état, et au-delà de cela de comprendre le comportement du système. Dans ce contexte, des techniques de visualisation de données ont été proposées [11, 21, 19], telles que les techniques de coordonnées parallèles, les matrices de nuage de points, etc. Des approches fondées sur les automates à états finis (FSA pour *Finite State Automata*), considérées comme représentations à faible dimension¹ impliquant une discrétisation des séries temporelles, ont également été proposées [26, 20]. Ces techniques réduisent la complexité algorithmique et offrent un haut niveau d'explicabilité – nous nous en inspirons pour proposer une représentation explicable d'un système de production d'énergie. Une telle représentation capture les états de tout ou partie du système en s'inscrivant dans le domaine de l'Intelligence Artificielle (IA) explicable (XAI) et intelligible [23].

Nous traitons le cas d'une centrale thermique qui brûle du charbon et du gaz afin de produire de la vapeur pour générer de l'électricité. Cette centrale dispose d'équipements (et d'ensemble d'équipements dont des chaudières, équipé(e)s de plusieurs centaines de capteurs) ayant des vocations différentes : transformer, consommer ou produire de l'énergie. La centrale est ainsi assimilée à un système complexe composé de séries temporelles multivariées non étiquetées, au comportement «chaotique» (i.e. irrégulier) et *a priori* non déterministe. Les experts du domaine industriel² contri-

1. I.e. résultant d'un processus de réduction des données dimensionnelles contenant autant d'informations que possible que les données d'origine.

2. Sociétés informatiques, éditeurs de logiciels, qui gèrent des données

*Contact author

buent en donnant leur avis sur le système. L'objectif est d'améliorer leur compréhension du fonctionnement de la centrale afin d'optimiser la consommation d'énergie.

Nos principales hypothèses sont les suivantes : (i) Les valeurs des séries temporelles à un instant donné représentent l'état du système en cet instant et permettent de détecter des états, en particulier les états « rares » ; (ii) les états du système peuvent être caractérisés par différentes métriques explicatives liées à l'évolution des séries temporelles : vitesse, vélocité et accélération des valeurs au sein d'un état ; (iii) les états du système, ainsi que leurs caractéristiques (métriques explicatives), peuvent être considérés comme faisant partie d'un FSA pour lequel il existe des représentations visuelles efficaces ; (iv) le FSA est une représentation synthétique, intelligible et compréhensible du comportement du système dans le temps et donc une aide à la décision.

Nous proposons une méthodologie de représentation explicite du comportement des systèmes complexes (XR-CSB pour *eXplainable Representation of Complex System Behavior*) utilisant les FSA pour les séries temporelles multivariées, fondée sur : (i) **L'extraction de connaissances** au travers de l'utilisation de *clustering vertical* des séries temporelles afin de détecter les états du système. Cette approche originale est indépendante de la taille des séries temporelles et applicable à des séries uni/multivariées, ce qui permet un contrôle de la complexité ; (ii) **la représentation de la connaissance explicable** par le biais de l'utilisation de FSA pour représenter le comportement du système, et (iii) **la prémodélisation de l'explicabilité** via l'utilisation de métriques explicatives pour enrichir les FSA, approche d'ingénierie des fonctionnalités explicables spécifiques au domaine (*pre-modeling explainability domain-specific explainable feature-engineering approaches*) [18].

La section 2 présente des travaux connexes sur l'XAI et la représentation des systèmes complexes. La méthode proposée est décrite dans la section 3, les résultats expérimentaux en section 4 – nous concluons en section 5.

2 État de l'art

Disposer de données étiquetées est très coûteux et parfois même impossible, ce qui a été le cas pour notre application – des méthodes non-supervisées doivent alors être appliquées [3]. Nous présentons ici des travaux liés à la compréhension et à la représentation du fonctionnement d'un système complexe dans ce contexte.

• **Clustering de séries temporelles multivariées** : les méthodes de clustering de séries temporelles multivariées [6, 1, 26] nécessitent que toutes les séries aient la même taille afin de garantir le bon fonctionnement du clustering et la fiabilité des résultats. Elles permettent de détecter des comportements communs entre les séries temporelles afin par exemple, d'étiqueter automatiquement celles-ci par la suite ou de détecter des motifs fréquents. Cependant, elles ne permettent pas de représenter le comportement caractérisé par les valeurs de différentes séries temporelles à un moment donné et ne sont donc pas adaptées à notre objectif.

moment donné et ne sont donc pas adaptées à notre objectif.

• **IA explicable (XAI)** : des modèles, très efficaces, de systèmes complexes existent [9]. Ils sont cependant souvent qualifiés de « boîtes noires » et l'XAI vise à les rendre plus intelligibles, plus transparents et plus accessibles ou encore à concevoir directement des modèles explicables [9, 10]. L'XAI a pour objectif de fournir une *explication* des mécanismes internes et/ou du comportement d'un système, sous la forme d'un ensemble d'énoncés construits pour décrire un ensemble de faits qui clarifie les causes, le contexte et les conséquences de ces faits [7]. Une explication est auto-suffisante et adressée au public cible selon sa connaissance *a priori* du domaine/système, de ses attentes et du contexte [22].

Une explication est donc une interface entre le système et le public cible (dans notre cas, les experts du domaine) [10, 14]. Les explications et l'intelligibilité peuvent, en effet, être beaucoup plus importantes que la *performance pure* dans les systèmes d'IA [10, 9], par exemple pour faciliter le contrôle et l'acceptation par l'utilisateur, ainsi que parfois pour des questions légales. Cela nécessite des compétences interdisciplinaires telles que l'interaction centrée sur l'homme ou une expertise en IA [17, 16, 2]. Les représentations visuelles jouent dans ce contexte un rôle important [24].

La majorité des méthodes de visualisation récentes traite de la visualisation du modèle de « boîte noire » à travers l'analyse de sensibilité [5], et ignore parfois les aspects liés à la multidimensionnalité des données. Il est important de noter que nous cherchons à représenter les résultats d'un modèle transparent (clustering) sur un système.

Soulignons les travaux de [13, 26] dans lesquels les séries temporelles sont segmentées au moyen de la détection des points de changement³. L'inconvénient de cette approche est qu'elle ne prend pas en compte les informations dynamiques et temporelles ainsi que l'interaction et la dépendance entre les séries temporelles.

• **Représentation de séries temporelles multivariées à l'aide d'automates** : l'utilisation de FSA – pour représenter, surveiller, estimer ou même prédire les états des systèmes – est d'une grande importance pour la prise de décisions émergeant de l'interaction experts-système.

Dans les travaux associés [6, 13, 26], des variables explicatives sont extraites de chaque série temporelle. Elles constituent les états du système et la succession de ces variables représente une séquence d'états. Un clustering est ensuite effectué pour détecter des modèles similaires (successions d'états) entre les séries temporelles. Ceci permet d'extraire un comportement commun partagé entre les séries temporelles, mais n'est applicable ni sur un très petit nombre de séries, ni à l'extraction du comportement global du système car l'interaction et la dépendance (ou non) entre les séries temporelles sont ignorées. Une telle approche n'est pas adaptée aux systèmes complexes car elle ne permet pas de

3. Un clustering destiné à traiter des données numériques "simple" (*k*-means par exemple pour les vecteurs numériques) est appliqué sur les variables explicatives et les fenêtres de données d'entrée.

simplification intelligible du comportement global du système.

3 Modèle XR-CSB : représentations explicables pour le comportement de systèmes complexes

Notre travail se concentre sur (i) l'étude des changements de comportement d'un système complexe représenté par des séries temporelles multivariées à différents pas de temps, (ii) la détection et la compréhension de l'évolution de l'état du système vers d'autres états, et (iii) la représentation de son évolution d'une manière intelligible et explicable.

Pour cela, nous proposons XR-CSB, un modèle en 3 étapes, inspiré de travaux de génération de FSA [15]. La figure 1 présente un schéma général du modèle.

3.1 Etape 1 : clustering vertical de séries temporelles

Afin d'effectuer ce que nous appelons un clustering vertical, nous utilisons l'algorithme k -means [25]. Notre point d'entrée est la série temporelle X représentée par un ensemble de vecteurs $X = [X_1, \dots, X_m]$ et une fenêtre temporelle fixe W de longueur w (mesurée en minutes). Nous appliquons k -means, avec la distance euclidienne, de manière à partitionner X en k clusters et ce indépendamment des pas de temps associés⁴. Les clusters obtenus, qui émergent des valeurs des différentes séries temporelles regroupées, représentent les états du système. Le choix de la valeur de k est fonction de la valeur de silhouette score calculée.

3.2 Etape 2 : explicabilité via des automates

Processus de génération d'automates (figure 4(a)) : Nous générons ensuite un automate où chaque nœud représente un état du système/cluster. La génération de l'automate suit les étapes suivantes décrite dans [15] : pour chaque vecteur X_t , un nœud est créé dans le FSA dont l'identifiant (id) est celui du cluster auquel le k -means l'a associé. Une arête directe est créée avec un poids de 1 entre le nœud en cours et celui créé. Si le nœud existe déjà dans l'automate, et l'arête également, le poids de celle-ci est incrémenté de 1. Sinon une nouvelle arête avec un poids de 1 est créée entre les deux nœuds existants. Dans le cas où deux vecteurs consécutifs X_t et X_{t+1} appartiennent au même cluster, une boucle récurrente est ajoutée au nœud associé. Ce processus aboutit à la génération d'un automate aux transitions pondérées représentant l'arrangement des clusters/états. La figure 4(a) représente l'automate résultant. Le poids des transitions est indiqué par une couleur, elle indique la durée pendant laquelle le système reste dans un état : plus elle est foncée, plus le poids de la transition est important.

4. La distance euclidienne ne tenant pas compte des différences d'échelles ou des possibles corrélations entre les séries temporelles permet de proposer une méthodologie générique transposable sur différents contextes d'applications et cela indépendamment des caractéristiques des séries temporelles.

Processus de génération de chemin : automate déplié (figures 4(b,d)) : Un *automate déplié* correspond à un chemin temporel le long des états du système. Nous proposons deux représentations visuelles d'un tel chemin et de l'évolution des états du système dans le temps : (1) la figure 4(b) représente la durée de chaque état via des informations numériques (durée des états en minutes, date UTC et UTC+2), et les mêmes nœuds/états possèdent le même identifiant ; (2) la figure 4(d) représente chaque état par un rectangle dont la taille est proportionnelle à la durée de l'état, et les mêmes états ont le même code-couleur.

3.3 Étape 3 : pré-modélisation du processus d'explicabilité, utilisation de métriques explicatives

Un processus d'explicabilité préalable à la modélisation consiste en l'extraction de métriques explicatives afin d'enrichir l'automate déplié. Afin de caractériser chaque état $S_{(t_{\text{start}}, t_{\text{end}})_i}$, nous proposons trois métriques à calculer pour chaque ensemble de vecteurs associés à la fenêtre $W \in [t_{\text{start}}, t_{\text{end}}]$:

- **la vitesse moyenne** : notée Sp , elle correspond à la valeur moyenne des vitesses de changement des valeurs entre les temps t et $t - 1$.
- **la vitesse moyenne** : notée Vl , elle correspond à la valeur moyenne des vitesses calculées pour chaque vitesse (la dynamique de l'évolution des valeurs)
- **l'accélération moyenne** : notée Ac , elle correspond à la valeur moyenne des accélérations et représente la rapidité de changement de la vitesse moyenne Sp des valeurs des états sur la fenêtre W .

À noter que si un état S_i se produit plusieurs fois dans une fenêtre W , alors les métriques explicatives seront calculées à chaque fois sur les vecteurs liés à l'état en question pendant cette fenêtre temporelle associée. La figure 4(c) représente un automate déplié enrichi de métriques explicatives.

4 Expérimentations

Nous présentons le jeu de données, puis une évaluation de la scalabilité de XR-CSB, ainsi qu'une évaluation qualitative visant à mesurer son pouvoir explicatif⁵.

4.1 Description des données industrielles

Notre jeu de données provient des capteurs des équipements d'une centrale thermique qui mesurent des quantités physiques différentes (tonne/h, °C, bar, etc). Les relevés de capteurs peuvent être renseignés ou non, sans forcément que cela soit une anomalie. Le jeu de données contient les enregistrements de 377 capteurs couvrant une période de trois ans, avec des valeurs collectées toutes les 10 minutes. Au niveau du pré-traitement, en fonction d'une fenêtre temporelle de largeur w (nombre de pas de temps)

5. Les expériences sont réalisées sur un MacBook Pro, Apple M1, 16GB de RAM. Le langage de programmation Python est utilisée, ainsi que les bibliothèques Numpy (<https://numpy.org/>), Scipy (<https://scipy.org/>), Matplotlib (<https://matplotlib.org/>), Networkx (<https://networkx.org/documentation/stable/index.html>), Scikit-learn (<https://scikit-learn.org/dev/index.html>) et Pandas (<https://pandas.pydata.org/docs/index.html>).

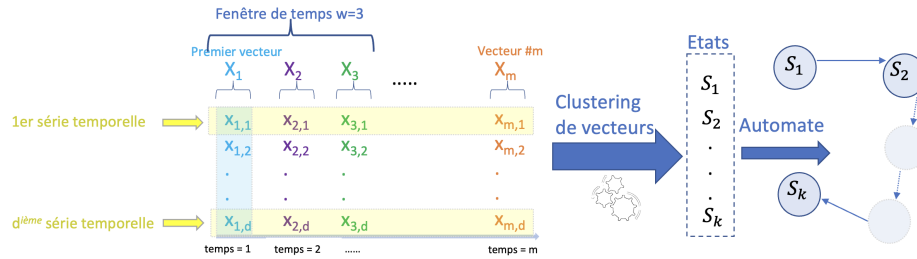


FIGURE 1 – Schéma général du modèle XR-CSB : séries temporelles multivariées, clustering et automates.

et d'un nombre de séries temporelles à analyser, le jeu de données est ainsi transformé en une matrice de dimension $(m \times d)$ où $m \in \{1, \dots, w\}$ et d est le nombre de séries temporelles. Le traitement peut être incrémental puisque la matrice est dynamique : pour chaque nouveau pas de temps, une colonne est ajoutée avec les valeurs des variables correspondantes. Toutes les valeurs sont normalisées (par la moyenne et l'écart-type). Lorsque $d > 1$, une moyenne est calculée à partir des valeurs normalisées.

4.2 Évaluation de la scalabilité

Nous avons évalué la scalabilité de notre approche en calculant le temps d'exécution pour 92 capteurs lorsque : (1) le nombre de clusters k varie sur une fenêtre de temps fixe de $w = 144$ pas de temps (figure 2), (2) lorsque la fenêtre de temps w varie pour $k = 7$ clusters (figure 3). Pour ces deux analyses, le temps d'exécution augmente presque linéairement et l'algorithme présente une bonne scalabilité pour les valeurs de w et k . Au niveau technique, notre évaluation de la scalabilité montre que ce modèle est non-coûteux en terme de temps d'exécution ou de puissance computationnelle. Notons que pour l'analyse de plus de deux ans d'enregistrements, il faut compter 20 minutes de temps de traitement, temps relativement raisonnable compte tenu du contexte industriel.

4.3 Évaluation de l'explicabilité

Les résultats de XR-CSB sont destinés aux experts du domaine de nos partenaires industriels. Ainsi, une évaluation *qualitative* a été faite via un questionnaire sur la qualité de la représentation et l'explicabilité du comportement d'un ensemble d'équipements. Composé de questions à choix multiples, le questionnaire porte sur trois études de cas et sur le profil de l'expert du domaine⁶.

4.4 Résultats

Nous proposons 3 études de cas : (i) **Cas d'étude A.1** : analyse d'un capteur C_1 dont l'unité physique est «tonnes par heure» (t/h) lorsque celui-ci présente un comportement monotone, (ii) **Cas d'étude A.2** lorsqu'il présente un comportement dynamique, (iii) **Cas d'étude B** : analyse des 92 capteurs d'un équipement B . Pour chaque cas d'utilisation, quatre représentations sont proposées (figure 4).

6. Les questions sur le genre et l'âge ont été exclues du questionnaire car jugées non pertinentes pour cette étude.

4.4.1 Profil des répondants

Profil professionnel : Parmi les six répondants, quatre sont des *data scientists*, un est ingénieur en apprentissage machine et un est directeur d'exploitation. Tous travaillent sur des systèmes complexes : trois depuis moins d'un an, un entre 1 et 2 ans et deux depuis plus de 5 ans. Enfin, tous utilisent des représentations visuelles dans leur travail quotidien pour expliquer ou transmettre des informations.

Confiance et explications du comportement de systèmes IA : quatre préfèrent les explications multi-modales (combinant plusieurs formes), un les représentations visuelles et un a répondu que seuls les résultats comptent (notamment en apprentissage machine supervisé). Notons toutefois qu'aucun ne préfère des explications unimodales (textuelles ou tabulaires) et que leur confiance dans les résultats des systèmes d'IA est fonction des «enjeux» traités.

Expérience professionnelle liée aux systèmes complexes : deux rencontrent «occasionnellement» le problème de la représentation du comportement des systèmes complexes dans le temps (50% des projets), trois rencontrent «parfois» (60% des projets) et un rencontre ce problème «régulièrement» (70% des projets).

4.4.2 Évaluation du pouvoir explicatif des représentations

Nous évaluons dans cette section l'acceptabilité de la représentation pour chacune des 3 études de cas. La figure 5 présente les résultats de l'évaluation par les experts industriels de l'explicabilité de chaque représentation de notre modèle pour chaque cas d'utilisation. Globalement, les représentations (b), (c) et (d) sont considérées comme «peu représentatives» ou «totalement représentatives». La représentation (a) n'a pas convaincu les experts. Sur les 3 études de cas, la représentation (d) s'est avérée la plus intéressante pour les experts. Enfin, les commentaires ajoutés par les experts montrent une préconisation à fusionner les représentations (b) et (d) décrites comme *intuitives et intéressantes car les états sont identifiables ainsi que les distributions temporelles*.

En résumé, les représentations dépliées ont reçu une bonne évaluation sur leur capacité à représenter le comportement d'un système dans le temps. La représentation (d) était particulièrement convaincante grâce aux systèmes de couleurs et à la simplicité de la visualisation, tout comme la représentation (b) (malgré une évaluation moins positive). La représentation (c), jugée intéressante (retour d'un répon-




FIGURE 2 – Analyse de 92 capteurs sur 24 heures (144 enregistrements) : Temps d’exécution calculé selon un nombre de clusters $k \in \{3, \dots, 100\}$.

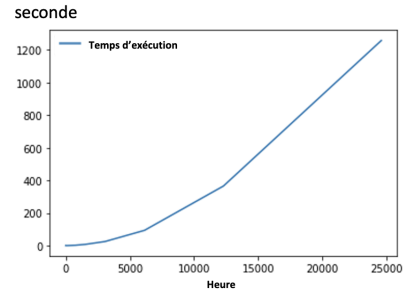


FIGURE 3 – Analyse de 92 capteurs pour $k = 7$: Temps d’exécution calculée selon la longueur de la fenêtre w avec $h \in \{8, 16, 24, 48, 96, 192, 384, 768, 1536, 3072, 6144, 12288, 24576\}$ heures.

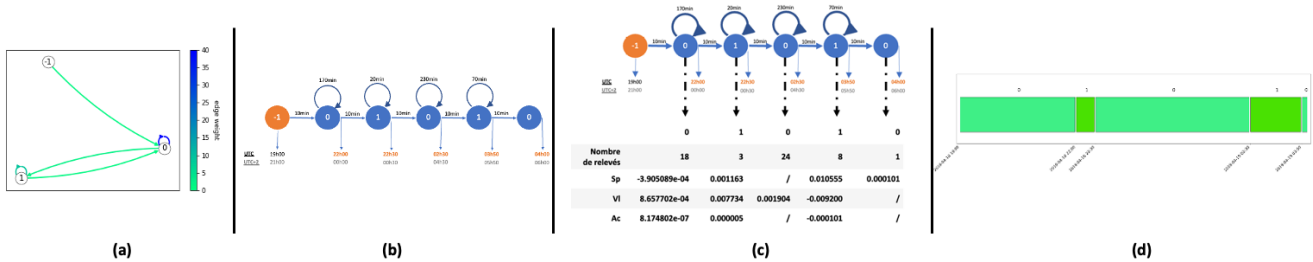


FIGURE 4 – Présentation des quatre représentations évaluées pour l’étude qualitative, résultant de l’analyse d’un seul capteur au comportement monotone (sans variation significative des valeurs) clusterisé avec $k = 2$. (a) un automate dont les couleurs des transitions indiquent leur poids : plus elle est foncée, plus le poids de la transition est élevé (le nœud -1 désignant le début de l’analyse, ne fait pas partie du groupe de données); (b) un automate déplié avec une représentation visuelle du temps pour chaque état par des valeurs numériques; (c) un automate déplié avec des métriques explicatives; (d) un automate déplié avec une représentation visuelle du temps pour chaque état.

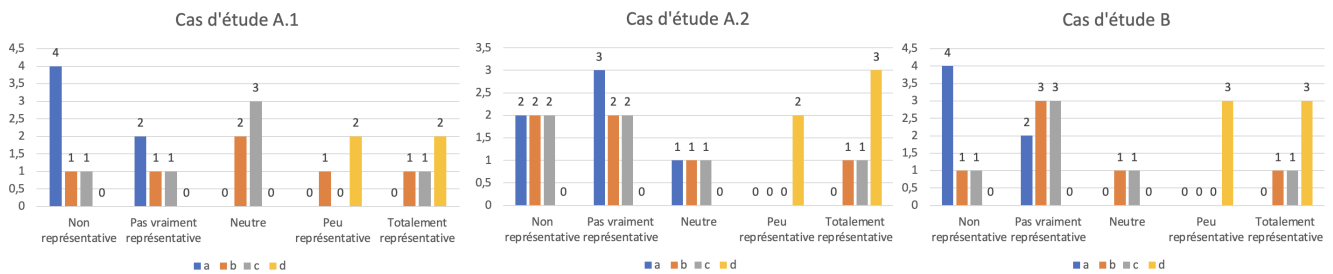


FIGURE 5 – Évaluation de l’explicitabilité de chaque représentation pour chaque cas d’utilisation. Les valeurs correspondent au nombre de répondants.

dant) mais limitée en termes d’explicitabilité du comportement, n’a suscité aucun rejet mais aucune adoption majeure non plus. Plusieurs facteurs peuvent expliquer ce résultat : (i) le choix des métriques et la création des représentations ont été faits par une approche orientée données (approche de *data science*), (ii) sans une forte implication des experts (notre public cible), (iii) sans un besoin explicite d’explicitabilité de leur part, et (iv) sans contexte sur l’objectif du présent travail. Enfin, le retour des experts sur les seuils d’intelligibilité des automates (entre 6 et 10 nœuds maximum) et le nombre de capteurs au delà duquel l’analyse du système devient complexe (entre 10 et 15 selon un expert senior) confirme que XR-CSB est en adéquation avec les besoins métier en terme de représentation visuelle ex-

pliquable du comportement d’un système complexe.

5 Conclusion et travaux futurs

XR-CSB est un travail original basé sur le clustering vertical et la génération d’automates dépliés pour décrire et comprendre le comportement d’un système complexe dans le temps. Notre étude montre que les représentations dépliées sont intéressantes pour les experts car elles donnent des informations sur le comportement du système, qu’il soit simple (une série temporelle) ou complexe (une centaine de séries temporelles), sur de courtes ou longues fenêtres de temps, que le comportement soit ponctuel (un pas de temps), ou non. Dans nos travaux futurs, nous souhaitons étudier les représentations que notre modèle permet d’ex-

traire afin de détecter les capteurs qui jouent un rôle discriminant dans le changement d'état du système complexe et intégrer cela dans notre explication du système. Cela pourrait aider les gestionnaires à identifier les équipements importants pour la gestion de l'énergie de l'installation, et plus globalement contribuer à la question de l'explicabilité des algorithmes de clustering appliqués aux séries temporelles.

Remerciements

Nous remercions le programme FEDER (Conseil régional de Bretagne et Union européenne) pour le financement du projet, les entreprises Energiency et Script&Go, et Raphaël Charbey (Energiency) pour son aide au sujet des visualisations.

Références

- [1] Saeed Reza Aghabozorgi, Ali Seyed Shirkhorshidi, and Ying Wah Teh. Time-series clustering - A decade review. *Inf. Syst.*, 53 :16–38, 2015.
- [2] Jean-Pierre Barthélemy, Gilles Coppin, and Philippe Lenca. Cognitive approach to decision making and practical tools. *IFAC*, 39(4) :123–128, 2006.
- [3] Agnès Braud, Pierre Gançarski, Corinne Grac, Agnès Herrmann, Florence Le Ber, and Harrison Vernier. Classification de séries temporelles hétérogènes pour le suivi de l'état des cours d'eau. In *EGC*, volume E-37 of *RNTI*, pages 71–82, 2021.
- [4] Leo Carlos-Sandberg and Christopher D Clack. Incorporation of causality structures to complex network analysis of time-varying behaviour of multivariate time series. *Scientific Reports*, 11(1) :18880, 2021.
- [5] Paulo Cortez and Mark J. Embrechts. Using sensitivity analysis and visualization techniques to open black box data mining models. *Inf. Sci.*, 225 :1–17, 2013.
- [6] Michel C. Desmarais and François Lemieux. Clustering and visualizing study state sequences. In *EDM*, pages 224–227, 2013.
- [7] Jess Drake. *Introduction to Logic*. Scientific e-Resources, 2018.
- [8] Janine Guespin-Michel. La science des systèmes complexes. <https://urlz.fr/hIxs>, 2016. Consulté : 2022-5-4.
- [9] Riccardo Guidotti, Anna Monreale, Salvatore Ruggieri, Franco Turini, Fosca Giannotti, and Dino Pedreschi. A survey of methods for explaining black box models. *ACM Comput. Surv.*, 51(5) :93 :1–93 :42, 2019.
- [10] David Gunning. Darpa's explainable artificial intelligence (XAI) program. In *IUI*. ACM, 2019.
- [11] David Harel. Statecharts : A visual formalism for complex systems. *Sci. Comput. Program*, 8(3) :231–274, 1987.
- [12] Forough Hassanibesheli, Niklas Boers, and Jürgen Kurths. Reconstructing complex system dynamics from time series : a method comparison. *New J. Phys.*, 22(7) :073053, 2020.
- [13] Bryan Higgs and Montasir Abbas. Segmentation and clustering of car-following behavior : Recognition of driving patterns. *IEEE Transactions on Intelligent Transportation Systems*, 16(1) :81–90, 2014.
- [14] Ikram Chraïbi Kaadoud, Lina Fahed, and Philippe Lenca. Explainable AI : a narrative review at the cross-road of knowledge discovery, knowledge representation and representation learning. In *MRC@IJCAI*, vol 2995 of CEUR Workshop Proceedings, pages 28–40, 2021.
- [15] Ikram Chraïbi Kaadoud, Nicolas P. Rougier, and Frédéric Alexandre. Knowledge extraction from the learning of sequences in a long short term memory (LSTM) architecture. *Knowl. Based Syst.*, 235 :107657, 2022.
- [16] Elisabeth Le Saux, Philippe Lenca, and Philippe Picouet. Dynamic adaptation of rules bases under cognitive constraints. *Eur. J. Oper. Res.*, 136(2) :299–309, 2002.
- [17] Philippe Lenca. Human centered processes. *Eur. J. Oper. Res.*, 136(2) :231–232, 2002.
- [18] Michal Moshkovitz, Sanjoy Dasgupta, Cyrus Rashtchian, and Nave Frost. Explainable k -means and k -medians clustering. In *Proceedings of ICML*, pages 7055–7065, 2020.
- [19] Vung Pham, Ngan Nguyen, Jie Li, Jon Hass, Yong Chen, and Tommy Dang. MTSAD : Multivariate time series abnormality detection and visualization. In *IEEE Big Data*, pages 3267–3276, 2019.
- [20] Miriam García Soto, Thomas A Henzinger, and Christian Schilling. Synthesis of hybrid automata with affine dynamics from time-series data. In *HSCC*, pages 1–11, 2021.
- [21] Andreas Theissler. *Detecting anomalies in multivariate time series from automotive systems*. PhD thesis, Brunel Univ. School of Engineering and Design, 2013.
- [22] Bas C. van Fraassen. The pragmatic theory of explanation. *Theories of Explanation*, 8 :136–155, 1988.
- [23] Daniel S Weld and Gagan Bansal. The challenge of crafting intelligible intelligence. *Commun. ACM*, 62(6) :70–79, 2019.
- [24] Fumeng Yang, Zhuanyi Huang, Jean Scholtz, and Dustin L Arendt. How do visual explanations foster end users' appropriate trust in machine learning? In *IUI*, pages 189–201, 2020.
- [25] Zheng Zeng, Rodney M. Goodman, and Padhraic Smyth. Learning finite-state machines with self-clustering recurrent networks. *Neural Comput.*, 5(6) :976–990, 1993.
- [26] Yihuan Zhang, Qin Lin, Jun Wang, and Sicco Verwer. Car-following behavior model learning using timed automata. *IFAC-PapersOnLine*, 50(1) :2353–2358, 2017.