



Traitement de signaux et synchronisation des données archéologiques et paléoenvironnementales à haute résolution : application de l'apprentissage automatique

par Abdou Niane

Mémoire présenté à l'Université du Québec à Chicoutimi en vue de l'obtention du grade de Maître ès sciences (M. Sc.) en informatique

Québec, Canada

© Abdou Niane, 2024

RÉSUMÉ

Ce mémoire présente une étude approfondie de l'analyse des séries temporelles dans le domaine de l'archéologie, en mettant particulièrement l'accent sur l'application des techniques d'apprentissage automatique pour traiter des données paléoenvironnementales à haute résolution. L'objectif principal de cette recherche est d'explorer les dynamiques historiques à travers l'analyse des traces dans des cavités, notamment dans la grotte de Nerja, en utilisant des approches novatrices telles que le Dynamic Time Warping et des algorithmes d'apprentissage automatique comme Random Forest et XGBoost.

L'étude s'articule autour de plusieurs axes clés, notamment la détection des pics dans les séries temporelles, le fenêtrage pour extraire des statistiques descriptives, et l'alignement des séries temporelles pour révéler des correspondances significatives entre différentes observations. Les résultats montrent que l'application de ces méthodes permet d'identifier des motifs pertinents et d'améliorer les prédictions des séries temporelles.

En outre, cette recherche souligne l'importance de la normalisation et du lissage des données pour garantir des analyses précises. Les expériences menées ont démontré que les algorithmes d'apprentissage automatique peuvent non seulement prédire des valeurs futures avec une précision notable, mais également détecter des anomalies dans les données, renforçant ainsi la valeur des analyses archéologiques.

Ce mémoire contribue à une meilleure compréhension des pratiques anciennes et ouvre la voie à de nouvelles perspectives dans l'étude des interactions entre les sociétés humaines et leur environnement. En intégrant des méthodes modernes à l'analyse archéologique, cette recherche incarne un pas vers une meilleure gestion et préservation du patrimoine historique.

ABSTRACT

This thesis presents an in-depth study of time series analysis within the field of archaeology, with a particular emphasis on the application of machine learning techniques to process high-resolution paleoenvironmental data. The primary objective of this research is to explore historical dynamics through the analysis of traces found in caves, notably in the Nerja cave, utilizing innovative approaches such as Dynamic Time Warping and machine learning algorithms like Random Forest and XGBoost.

The study is structured around several key axes, including peak detection in time series, windowing to extract descriptive statistics, and the alignment of time series to reveal significant correspondences between different observations. The results demonstrate that the application of these methods enables the identification of relevant patterns and enhances predictions of time series.

Furthermore, this research highlights the importance of normalization and smoothing of data to ensure precise analyses. The experiments conducted show that machine learning algorithms can not only predict future values with notable accuracy but also detect anomalies within the data, thereby reinforcing the value of archaeological analyses.

This thesis contributes to a better understanding of ancient practices and paves the way for new perspectives in the study of interactions between human societies and their environment. By integrating modern methods into archaeological analysis, this research represents a significant step toward better management and preservation of historical heritage.

TABLE DES MATIÈRES

RÉSUMÉ	ii
ABSTRACT	ii
TABLE DES MATIÈRES	iii
LISTE DES TABLEAUX	vi
LISTE DES FIGURES	vii
LISTE DES ABRÉVIATIONS	ix
DÉDICACE	x
REMERCIEMENTS	xi
CHAPITRE 1 - INTRODUCTION	1
1.1 CONTEXTE	1
1.2 PROBLEMATIQUE	4
1.3 CONTRIBUTION	6
1.4 METHODOLOGIE	7
1.5 ORGANISATION DU MEMOIRE	8
CHAPITRE 2 - REVUE DE LITTÉRATURE	10
2.1 FENÊTRAGE	10
2.1.1 TYPES DE FENÊTRAGE	12
2.1.2 STATISTIQUES SUR LES SÉRIES TEMPORELLES	20
2.2 APPRENTISSAGE AUTOMATIQUE	28
2.2.1 APPLICATIONS DE L'INTELLIGENCE ARTIFICIELLE EN ARCHÉOLOGIE	32
2.2.1.1 DÉTECTION DE SITES ARCHÉOLOGIQUES	32
2.2.1.2 ANALYSE BIOMÉDICALE BASÉE SUR LES COMMUNAUTÉS MAMMIFÈRES	34
2.2.1.3 DÉTECTION D'ANOMALIES DANS LES DONNÉES SÉDIMENTAIRES	36
2.2.1.4 CLASSIFICATION DES VERRES ANCIENS	38
2.2.2 APPROCHES APPRENTISSAGE PROFOND	40
2.2.2.1 RÉSEAUX DE NEURONES RÉCURRENTS	41

2.2.2.2 TRANSFORMEURS	41
2.2.2.3 AUROENCODEURS POUR LES SÉRIES TEMPORELLES	42
2.2.3 DISCUSSION.....	42
2.3 ALIGNEMENT DES SÉRIES TEMPORELLES	43
2.3.1 DYNAMIC TIME WARPING.....	43
2.3.2 CAS D'APPLICATION DU DTW.....	45
2.3.2.1 RECONNAISSANCE DE LA PAROLE	45
2.3.2.2 ANALYSE D'EXPRESSION GÉNIQUE	47
2.3.2.3 PRÉVISION DES PRIX DES ACTIONS	48
2.3.3 PRINCIPALES VARIANTES DU DTW	49
2.3.3.1 FAST DTW.....	49
2.3.3.2 SHAPE DTW :	51
2.3.3.3 WEIGHTED DTW :	53
2.3.3.4 DERIVATIVE DTW :	55
2.3.4 DISCUSSION.....	57
2.4 CONCLUSION	58
CHAPITRE 3 - ANALYSE DES SERIES TEMPORELLES DANS L'ARCHEOLOGIE	59
3.1 PRESENTATION DU CONTEXTE, DES DONNEES.....	59
3.1.1 CONTEXTE.....	59
3.1.2 DONNEES	61
3.2 DETECTION DES POINTES DANS LES SERIES TEMPORELLES	64
3.2.1 METHODOOGIE.....	64
3.2.2 RESULTATS	65
3.2.3 APPLICATION ET INTERPRETATION ARCHEOLOGIQUE	68
3.3 FENETRAGE POUR STATISTIQUES ET APPRENTISSAGE AUTOMATIQUE CLASSIQUE	68
3.3.1 FENETRAGE	69
3.3.2 STATISTIQUES UTILISEES.....	70
3.3.3 PREDICTION DES SERIES TEMPORELLES	72

3.4 ALIGNEMENT DES SERIES TEMPORELLES	76
3.4.1 TESTS ET VISUALISATION DES ALIGNEMENTS	78
3.4.2 ANALYSE DES RESULTATS.....	81
3.5 CONCLUSION	85
CHAPITRE 4 - CONCLUSION	86
4.1 REVUE DES CONTRIBUTIONS	86
4.2 LIMITES	87
4.3 TRAVAUX FUTURS	88
4.4 APPORT PERSONNEL	90
BIBLIOGRAPHIE.....	91

LISTE DES TABLEAUX

TABLEAU 1 : PERFORMANCE DES APPROCHES DE FENETRAGE	19
TABLEAU 2 : F-MESURE PAR ACTIVITE	19
TABLEAU 3 : APERÇU DE LA COMPARAISON DES PERFORMANCES DES MODELES	36
TABLEAU 4 : COMPARAISON DES PERFORMANCES DES MODELES.....	40
TABLEAU 5 : COMPARAISON DES TAUX D'ERREUR DE RECONNAISSANCE	46
TABLEAU 6 : PRECISION DE FASTDTW PAR RAPPORT A D'AUTRES METHODES.....	50
TABLEAU 7 : TEMPS DE CALCUL DE FASTDTW PAR RAPPORT AU DTW STANDARD	51
TABLEAU 8 : RESUME DES PERFORMANCES DE CLASSIFICATION.....	54
TABLEAU 9 : COMPARAISON DU WARPING SPURIOUS ENTRE DTW ET DDTW	56
TABLEAU 10 : COMPARAISON DE L'ALIGNEMENT CORRECT ENTRE DTW ET DDTW.....	57
TABLEAU 11: COMPARAISON DES PERFORMANCES DES MODELES.....	74

LISTE DES FIGURES

FIGURE 1 : EXEMPLE DE SERIE TEMPORELLE AVEC TENDANCES ET SAISONNALITES.....	12
FIGURE 2 : ILLUSTRATION DU FENETRAGE AVEC FENETRES DE TAILLE FIXE	13
FIGURE 3 : FENETRAGE TEMPOREL DE LA SERIE TEMPORELLE	14
FIGURE 4 : FENETRAGE BASE SUR DES EVENEMENTS DE LA SERIE TEMPORELLE	15
FIGURE 5 : FENETRAGE DYNAMIQUE DE LA SERIE TEMPORELLE	16
FIGURE 6 : SERIE TEMPORELLE AVEC MOYENNE ET ECART-TYPE ROULANTS	22
FIGURE 7 : ILLUSTRATION DE LA PREVISION DES VENTES AVEC ARIMA	24
FIGURE 8 : PREVISIONS DE LA DEMANDE AVEC LISSAGE EXPONENTIEL TRIPLE.....	26
FIGURE 9 : SELECTION INTELLIGENTE DES DONNEES DE CAPTEURS	28
FIGURE 10 : PREDICTIONS DE PRIX DE MAISONS AVEC REGRESSION LINEAIRE	29
FIGURE 11 : CLUSTERING DE CLIENTS AVEC K-MEANS.....	30
FIGURE 12 : PROCESSUS DE L'APPRENTISSAGE PAR RENFORCEMENT.....	31
FIGURE 13 : EXEMPLE D'ALIGNEMENT DE DEUX SERIES TEMPORELLES AVEC DTW.....	44
FIGURE 14: <i>LOCALIZATION GEOGRAPHIC OF NERJA CAVE (MÁLAGA, SPAIN). SOURCE: INSTITUTO DE ESTADÍSTICA Y CARTOGRAFÍA DE ANDALUCÍA.....</i>	60
FIGURE 15: GROTTES DE NERJA.....	61
FIGURE 16: <i>TOPOGRAPHIC PLAN OF NERJA CAVE WITH THE LOCALIZATION OF THE DIFFERENT SECTORS EMPLOYED IN SYSTEMATIC SURVEYING. MODIFIED FROM F. RAMÍREZ ET AL. 1985.</i>	62
FIGURE 17: APERÇU DES 10 PREMIERES LIGNES ET COLONNES DES DONNEES	63
FIGURE 18: DETECTION DES PICS POUR SR88 AVEC LA METHODE DU Z-SCORE	66
FIGURE 19: DETECTION DES PICS POUR SR88 AVEC LA METHODE DE LA DERIVEE.....	67
FIGURE 20: DETECTION DES PICS POUR SR88 AVEC LA METHODE FIND_PEAKS	67
FIGURE 21: ÉVOLUTION DE LA MOYENNE ET DE L'ECART-TYPE.....	71
FIGURE 22: ÉVOLUTION DE LA SOMME CUMULEE DANS CHAQUE FENETRE	72
FIGURE 23: COMPARAISON DES VALEURS REELLES ET PREDITES PAR XGBOOST	75

FIGURE 24: ZOOM SUR LES 100 PREMIERES OBSERVATIONS	76
FIGURE 25: SCAN GN16-8 REALISE PAR LA-ICP-MS	77
FIGURE 26: SCAN GN16-7-1 REALISE PAR LA-ICP-MS.....	77
FIGURE 27: ALIGNEMENT DES SERIES TEMPORELLES AVEC DTW.....	80
FIGURE 28: ZOOM DE L'ALIGNEMENT ENTRE DEUX POINTS.....	80
FIGURE 29: COMPARAISON DES SERIES AVANT ET APRES ALIGNEMENT DTW	82
FIGURE 30: ILLUSTRATION DE LA SERIE 1 ET DE LA SERIE 2 ALIGNEE.....	82
FIGURE 31: ALIGNEMENT DTW SUR DES SERIES SYNCHRONISEES PARTIELLEMENT	84
FIGURE 32: ILLUSTRATION DE LA SERIE 1 ET DE LA SERIE 2 ALIGNEE.....	84

LISTE DES ABRÉVIATIONS

IA	Intelligence Artificielle
DTW	Dynamic Time Warping
KNN	K-Nearest Neighbors
RF	Random Forest
SVM	Support Vector Machine
XGBoost	Extreme Gradient Boosting
RNN	Recurrent Neural Network
ARIMA	Autoregressive Integrated Moving Average
RMSE	Root Mean Square Error
R²	Coefficient of Determination
LSTM	Long Short-Term Memory
FastDTW	Fast Dynamic Time Warping
WDTW	Weighted Dynamic Time Warping
ShapeDTW	Shape Dynamic Time Warping
DDTW	Derivate Dynamic Time Warping
LOI	Loss on Ignition
XRF	X-ray Fluorescence

DÉDICACE

À mes parents, piliers de ma vie, qui m'ont offert l'amour, le soutien, et l'inspiration nécessaires pour me dépasser.

À mes frères et sœurs, compagnons de route dans cette aventure qu'est la vie, qui m'ont donné la force dans les moments de doute et la joie dans les moments de succès.

À mes amis, dont la présence et l'amitié m'ont souvent rappelé que même dans les périodes de travail intense, le lien humain reste essentiel.

Ce travail est le reflet de vos encouragements, de votre patience, et de votre foi en moi. Je vous dédie cet accomplissement avec une profonde reconnaissance.

REMERCIEMENTS

Ce mémoire n'aurait jamais vu le jour sans le soutien indéfectible et les conseils avisés de ceux qui m'ont accompagné tout au long de ce parcours.

Je tiens à exprimer ma plus profonde gratitude à Kévin Bouchard, mon directeur de recherche, pour m'avoir guidé avec passion dans le monde fascinant de l'intelligence artificielle. Grâce à son expertise et à ses encouragements, j'ai pu franchir des étapes que je n'aurais jamais cru possibles.

Je souhaite également remercier chaleureusement ma co-directrice de recherche, Ségolène Vandeveld, qui a su éveiller en moi un intérêt sincère pour l'archéologie. Sa patience et sa pédagogie m'ont permis de me plonger dans un univers inconnu et de découvrir la beauté de la recherche interdisciplinaire.

Je remercie tout particulièrement l'ensemble des professeurs et du personnel du département d'informatique et de mathématique de l'Université du Québec à Chicoutimi, pour leur enseignement et leur soutien constant, qui ont enrichi mon parcours académique.

Un immense merci à ma famille, qui a toujours été mon refuge et mon moteur. Vous avez cru en moi, même dans les moments de doute, et c'est cette confiance qui m'a permis de poursuivre et de finaliser ce mémoire.

À vous tous, je suis profondément reconnaissant.

CHAPITRE 1 INTRODUCTION

1.1 CONTEXTE

Au début du XX^e siècle, les seules personnes qui pouvaient travailler en archéologie étaient celles issues de milieux aisés qui possédaient le temps, l'argent et la curiosité intellectuelle nécessaires pour poursuivre dans ce domaine. Les chercheurs peuvent prétendre que l'archéologie était vraiment réservée aux personnes hautement éduquées puisque toutes les personnes impliquées étaient une autorité dans leur propre domaine d'étude (Singh, Rai et al. 2023). Avec l'expansion de l'archéologie, la collecte d'informations lors des fouilles est devenue plus méthodique et systématique, ce qui a permis de recueillir des données plus précises et plus complètes (Singh, Rai et al. 2023).

Les progrès méthodologiques réalisés dans de nombreuses sous-disciplines de l'archéologie permettent aujourd'hui d'étudier de nombreux aspects de l'«économie» des sociétés passées (activités de subsistance telles que la chasse, la pêche ou l'obtention de matières premières) de manière beaucoup plus détaillée qu'auparavant. Cependant, de nombreuses questions restent difficiles à aborder et restent sans réponse en raison du manque de résolution temporelle des données archéologiques. En effet, les méthodes conventionnelles d'étude des vestiges archéologiques, et notamment préhistoriques, permettent difficilement d'établir des chronologies à haute résolution (Vandeveld 2024: 566). La nature cumulative des couches archéologiques peut également rendre difficile l'interprétation des éléments trouvés dans une seule couche, puisque les assemblages archéologiques (tous les vestiges trouvés dans un seul contexte, comme dans une couche archéologique) sont formés par l'accumulation et le mélange de vestiges provenant de multiples occupations successives (Vandeveld, Brochier et al. 2019).

Au cours de la dernière décennie, de nombreux efforts, notamment dans le développement de techniques analytiques (Leierer, Jambriña-Enríquez et al. 2019), ont été consacrés à l'obtention d'un niveau plus élevé de résolution temporelle pour la datation de matériaux anciens (Vandavelde 2024: 566). Parmi ces méthodes, la fuliginochronologie, qui utilise les traces de suie enregistrées dans les concrétions calcaires comme marqueurs de la présence humaine sur les sites, a permis d'atteindre une résolution temporelle jusqu'alors inégalée pour des périodes si reculées (Vandavelde, Brochier et al. 2017, Vandavelde, Genty et al. 2020).

La pyroarchéologie, qui consiste à étudier les traces laissées dans les cavités, représente un domaine clé de la recherche archéologique. Ces traces, emprisonnées dans des concrétions calcaires, fournissent des indices précieux sur l'utilisation du feu, la cuisson des aliments, la fabrication d'objets et d'autres aspects de la vie ancienne (Vandavelde 2019). L'analyse micro-chronologique des dépôts de suie permet de reconstruire les occupations humaines passées et de comprendre les pratiques culturelles et les activités quotidiennes des populations antérieures. De plus, la haute résolution temporelle est essentielle pour l'étude de l'organisation socio-culturelle des sociétés et la compréhension des transitions historiques.

Les dépôts de suie, marqueurs de la fréquentation des sites en cavités par les humains, peuvent être enregistrés dans des archives sédimentaires comme les spéléothèmes (concrétions calcaires comme les stalactites ou les stalagmites) ; la résolution temporelle des données dépend directement de la résolution temporelle de cette archive. Les spéléothèmes peuvent être formés de doublets de calcite annuels (visibles ou non en microscopie) et un moyen fiable de les détecter est de mesurer les variations de la concentration en certains éléments traces (Mg, Sr, Ba, U), connus pour présenter des fluctuations annuelles dans les spéléothèmes. Détecter ces fluctuations permet d'obtenir un calendrier annuel de précipitation des carbonates de calcium. En remplaçant le signal anthropique (les dépôts de suie) dans ce signal paléo-environnemental (calendrier annuel), il devient possible d'étudier les dynamiques de fréquentation des sites archéologiques avec une très haute résolution temporelle (Vandavelde, Lacour et al. 2021).

En parallèle, l'intelligence artificielle (IA) s'est développée comme la science qui tente de comprendre et reproduire les comportements intelligents. Plus spécifiquement, l'apprentissage automatique s'est imposé comme étant le plus gros sous-domaine de l'IA et est devenu très populaire et perversif dans les dernières décennies (Russell 2010). L'utilisation de l'intelligence artificielle dans les nombreux sous-domaines de l'archéologie présente certaines similitudes, telles que la reconnaissance automatique des images pour l'identification des structures archéologiques ou l'analyse des données géospatiales pour détecter des sites enfouis sous la végétation; mais, dans d'autres cas, son application sera utilisée différemment, par exemple dans l'analyse des sédiments pour reconstituer les environnements anciens ou dans la détection d'anomalies pour identifier des événements passés, comme des transgressions marines (Chen 2022). Aujourd'hui, les archéologues utilisent une grande variété d'approches d'apprentissage automatique, qui les assistent dans une variété de procédures analytiques et leur permettent d'obtenir des connaissances plus précises sur le passé (Gera 2022). Ces approches incluent le traitement de grandes quantités de données, l'identification de motifs et de relations complexes, et la prédiction de scénarios passés.

Des recherches ont montré l'efficacité de l'apprentissage automatique dans des contextes archéologiques. Par exemple, Orengo et Garcia-Molsosa (2019) ont utilisé des techniques comme le *Random Forest* pour détecter des tessons de poterie à l'aide d'images de drones haute résolution dans des sites archéologiques en Sardaigne. Leur étude a démontré comment l'apprentissage automatique peut être appliqué pour interpréter des données complexes et nous aider à améliorer notre compréhension des interactions entre les sociétés humaines et leur environnement. Bien que l'application des méthodes d'apprentissage automatique en archéologie soit relativement récente, certaines techniques d'analyse de séries temporelles, comme le *Dynamic Time Warping (DTW)*, introduit par Sakoe et Chiba (1978), ont été adaptées à des études archéologiques pour aligner et comparer des séries temporelles, améliorant ainsi la précision des analyses.

Ainsi, l'apprentissage automatique émerge comme une approche prometteuse pour traiter et synchroniser des données complexes à haute résolution. Il peut aider à extraire des informations

significatives des données archéologiques et paléoenvironnementales, permettant non seulement de gérer efficacement le volume élevé de données, mais aussi de découvrir des modèles et des tendances cachées, de prédire des scénarios passés et de faciliter la prise de décisions éclairées en matière de conservation et de gestion des sites archéologiques.

1.2 PROBLEMATIQUE

La science des données et l'apprentissage automatique jouent un rôle croissant dans l'analyse des données complexes, y compris en archéologie (Doshi-Velez et Kim 2017). Ces disciplines, qui combinent des techniques issues des statistiques, de l'informatique et de l'expertise des domaines d'application, permettent de traiter des volumes importants de données hétérogènes et de résoudre des problèmes complexes (Fawcett et Provost 2013).

L'apprentissage automatique, une branche de l'intelligence artificielle, est essentiel dans ce contexte. Il permet de développer des algorithmes capables d'apprendre à partir de données et de faire des prédictions ou des classifications sans nécessiter de programmation explicite pour chaque tâche (Mitchell 1997). Dans des domaines comme l'archéologie, ces algorithmes offrent des outils puissants pour identifier des motifs cachés, classer des artefacts ou analyser des séries temporelles complexes (Oonk et Spijker 2015).

Dans ce mémoire, nous appliquons ces concepts pour aborder les défis spécifiques rencontrés dans l'étude de données archéologiques et paléoenvironnementales. Les méthodes d'analyse classiques sont souvent limitées par la complexité, l'incomplétude et la dispersion des données dans le temps et l'espace. L'objectif de cette recherche est donc de développer et d'appliquer des techniques d'apprentissage automatique pour traiter et synchroniser des séries temporelles à haute résolution, en surmontant ces obstacles afin d'obtenir une compréhension plus précise des dynamiques passées.

Notre étude se concentre sur l'analyse de spéléothèmes (concrétions calcaires telles que les stalactites et stalagmites qui se forment dans les cavités) qui enregistrent des dépôts de suie dans les cavités de la grotte de Nerja, un site archéologique majeur du paléolithique supérieur. Ces dépôts, témoins des activités humaines comme l'utilisation du feu pour l'éclairage nécessaire à l'exploration de la grotte par les populations passées (Medina-Alcaide, Vandavelde et al. 2023), fournissent des informations précieuses sur les pratiques anciennes et les dynamiques de fréquentation du site. Les échantillons analysés dans cette étude ont été prélevés dans différentes sections de la grotte, puis scindés en quatre pour permettre différentes analyses (datation, minéralogie, fuliginochronologie, etc.). Un des fragments ayant été préparé en section polie (polie miroir), pour permettre des analyses par Spectrométrie de Masse à Plasma à Couplage Inductif avec Ablation Laser (LA-ICP-MS). Cette technique permet de détecter des éléments traces et les variations de leurs concentrations dans les dépôts, comme cela a été fait dans des études sur les spéléothèmes pour identifier des cycles annuels (Nagra, Treble et al. 2017). Dans notre cas, des transects ont été réalisés tout au long des échantillons, obtenant ainsi pour chaque élément analysé une série de mesures (données).

Dans cette recherche, nous avons appliqué des techniques de détection de motifs, de classification, et de prédiction à partir de ces données, en utilisant notamment des algorithmes tels que le *random forest* et des techniques de fenêtrage pour calculer des statistiques descriptives (Orengo, Conesa et al. 2020). Cela nous a permis d'identifier des tendances temporelles significatives et de mieux comprendre les variations dans les spéléothèmes sur de courtes périodes.

Un autre défi majeur réside dans la gestion et l'analyse de grandes quantités de données provenant de diverses sources et que l'on cherche à synchroniser (par exemple de séries de données venant de différents échantillons contemporains). Nous avons utilisé des techniques d'alignement des séries temporelles, telles que le *Dynamic Time Warping*, pour synchroniser les données et détecter des correspondances entre les différents ensembles de données (Wang, Shi et al. 2023). Ces méthodes ont permis d'intégrer des données provenant de diverses sources pour confirmer des observations ou pour avoir des informations plus complètes dans l'optique de mieux comprendre les

relations entre les événements humains et environnementaux. Enfin, cette étude vise à reconstituer les scénarios historiques en modélisant les interactions entre les humains et leur environnement à travers des techniques d'apprentissage automatique.

En parallèle, cette recherche encourage les collaborations interdisciplinaires entre archéologues, géologues et spécialistes en science des données afin d'enrichir les méthodes de recherche et d'accroître la portée des découvertes (Galeazzi, Callieri et al. 2016). L'apprentissage automatique et ses applications en archéologie pourraient transformer les méthodes de recherche, ouvrant la voie à de nouvelles approches pour analyser, interpréter et préserver le patrimoine historique.

1.3 CONTRIBUTION

La contribution de cette recherche réside dans l'application de techniques d'apprentissage automatique pour améliorer l'analyse des séries temporelles dans le domaine de l'archéologie. En développant des méthodologies robustes pour la détection des points d'intérêt et l'alignement des séries, cette étude a permis d'extraire des informations significatives des données paléoenvironnementales complexes en contexte archéologique.

L'utilisation de l'algorithme *Dynamic Time Warping* a facilité l'identification de motifs et de tendances dans les données, tandis que les modèles d'apprentissage automatique tels que *K-Nearest Neighbors (KNN)*, *Random Forest (RF)* et le *Extreme Gradient Boosting (XGBoost)* ont démontré leur capacité à prédire des valeurs futures.

Ce mémoire pose également les bases d'un cadre méthodologique pour extraire un cadre chronologique de haute résolution (chronomètre annuel) grâce au traitement de certaines données paléoenvironnementales, ouvrant ainsi des perspectives pour des recherches futures. En outre, ma participation en tant que co-auteur à un article scientifique a enrichi cette étude, renforçant

l'importance de l'application de techniques d'analyse de données dans l'archéologie. Dans l'ensemble, cette recherche contribue à une meilleure compréhension des dynamiques archéologiques et met en lumière le potentiel des méthodes modernes dans l'analyse des données anciennes.

1.4 METHODOLOGIE

Notre approche méthodologique pour ce projet de recherche comprend cinq étapes principales qui ont guidé notre recherche (de manière systématique et rigoureuse) afin d'atteindre nos objectifs.

Tout d'abord, nous avons défini la problématique de la recherche et réalisé une revue de littérature approfondie pour examiner les travaux antérieurs liés à notre projet. Cette revue de littérature s'est concentrée sur les études traitant du fenêtrage et des statistiques liées aux séries temporelles, ainsi que sur les méthodes d'alignement des séries temporelles et leurs applications dans des contextes similaires, tels que l'analyse des données paléoenvironnementales, la détection des sites historiques et la reconstruction des dynamiques passées dans des études archéologiques.

Ensuite, nous avons procédé à l'analyse et à la préparation des données paléoenvironnementales (variations de la concentration en éléments traces dans les spéléothèmes) dans les cavités, fournies par l'archéologue. Cette étape a impliqué le nettoyage des données, y compris l'élimination des valeurs aberrantes et le traitement des données manquantes. Des techniques de prétraitement des séries temporelles ont été utilisées pour garantir la qualité et la cohérence des données avant l'analyse.

Sur la base de la revue de littérature et de l'analyse des données, nous avons formulé des hypothèses de recherche concernant les motifs et les variations temporelles dans les spéléothèmes. Un prototype de modèle d'apprentissage automatique a été développé pour tester ces hypothèses. Ce modèle a été conçu pour l'identification des motifs significatifs, les techniques de fenêtrage, le

calcul de statistiques descriptives, et les méthodes d'alignement des séries temporelles en utilisant des algorithmes.

Les expérimentations ont constitué une étape clé de notre projet. Nous avons appliqué des techniques de fenêtrage pour calculer des statistiques descriptives, ce qui a offert une meilleure compréhension des variations temporelles dans nos données. De plus, nous avons utilisé des techniques d'apprentissage automatique classique pour la prédiction des résultats. Les méthodes d'alignement des séries temporelles, telles que le DTW, ont été explorées pour trouver des motifs ou des similarités dans les données. Les expérimentations ont été réalisées en utilisant des ensembles de données d'entraînement et de test pour évaluer la performance des modèles.

Enfin, les résultats des expérimentations ont été analysés et discutés en détail. Nous avons évalué la justesse des modèles et comparé les résultats obtenus. Les découvertes significatives ont été mises en évidence, et des recommandations pour les futures recherches ont été formulées. L'utilisation de techniques d'apprentissage automatique a permis de révéler des tendances cachées et d'améliorer notre compréhension de ces données archéologiques et paléoenvironnementales.

1.5 ORGANISATION DU MEMOIRE

Le Chapitre 1 a établi le cadre général de la recherche en mettant en lumière le contexte scientifique et les enjeux méthodologiques sous-jacents. Nous avons exposé la problématique qui a suscité notre étude et discuté des défis inhérents à l'analyse de séries temporelles. En outre, nous avons présenté les contributions majeures de cette recherche ainsi que la méthodologie globale que nous avons adoptée pour résoudre ces défis. Cette introduction a également offert un aperçu de l'organisation du mémoire.

Dans le Chapitre 2 nous avons fait une revue de la littérature dans le domaine du traitement et de l'analyse des séries temporelles. Nous avons exploré en détail les approches de fenêtrage et

les statistiques associées aux séries temporelles, mettant en évidence les méthodes traditionnelles ainsi que les avancées récentes. De plus, nous avons examiné les techniques d'alignement des séries temporelles, en analysant leurs avantages et limitations. Cette revue de littérature a éclairé les bases théoriques et méthodologiques de notre recherche.

Le Chapitre 3 est dédié à l'exploration des séries temporelles spécifiques à l'archéologie et aux paléoenvironnements. Nous avons présenté le contexte de nos données, en décrivant les formats utilisés et les traitements nécessaires pour leur préparation.

Une partie importante de ce chapitre est portée sur la détection des pointes dans les séries temporelles, où sont détaillées les méthodologies et algorithmes appliqués, accompagnés d'exemples et de résultats concrets. Le fenêtrage pour les statistiques et l'apprentissage automatique est ensuite abordé, expliquant comment des fenêtres temporelles ont été créées et quelles statistiques ont été utilisées pour caractériser les données. Enfin, les méthodes d'alignement des séries temporelles sont présentées, et les résultats obtenus grâce à différentes approches sont examinés.

Le Chapitre 4 a conclu notre étude en résumant les contributions clés de notre recherche, en discutant des implications de nos résultats et en suggérant des orientations pour des travaux futurs. Nous y avons également abordé les limites de notre étude et proposé des pistes pour les surmonter dans les recherches ultérieures.

CHAPITRE 2 REVUE DE LITTÉRATURE

L'analyse des séries temporelles est une composante essentielle de nombreux domaines scientifiques et technologiques, y compris en archéologie, où elle permet de déchiffrer des motifs et des tendances historiques à partir de données séquentielles. La revue de la littérature présentée dans ce chapitre vise à fournir un cadre théorique et méthodologique pour comprendre les méthodes actuelles de traitement et d'analyse des séries temporelles. Nous nous sommes d'abord concentrés sur les travaux relatifs au fenêtrage et aux statistiques associées aux séries temporelles, puis nous avons examiné les applications de l'apprentissage automatique dans ce contexte, et enfin, nous avons abordé les techniques d'alignement des séries temporelles.

2.1 FENÊTRAGE

Avant d'explorer les approches spécifiques de fenêtrage et de statistiques liées aux séries temporelles, il est essentiel de comprendre en quoi consistent les séries temporelles. Selon Brockwell et Davis (2016), une série temporelle est définie comme un ensemble de points de données ordonnés chronologiquement, permettant de visualiser comment une variable évolue dans le temps. En outre, Shumway et Stoffer (2017) mettent en avant l'utilité des séries temporelles pour identifier des tendances, des cycles, et des modèles saisonniers dans les données. Ils soulignent également que l'analyse des séries temporelles est cruciale dans de nombreux domaines, allant de l'économie à l'ingénierie, en passant par les sciences naturelles et sociales. De plus, Chatfield (2016) met l'accent sur l'importance des dépendances temporelles dans les séries temporelles. Il explique que, contrairement aux données transversales, les observations successives dans une série temporelle sont généralement dépendantes, ce qui nécessite des méthodes d'analyse spécifiques pour tenir compte de cette autocorrélation.

L'analyse des séries temporelles occupe une place cruciale dans la compréhension des phénomènes dynamiques qui se manifestent à travers le temps. Cependant, ces séries, souvent complexes et volumineuses, nécessitent des méthodes et des techniques adaptées pour en extraire des informations significatives (Shumway et Stoffer 2017).

Les séries temporelles sont omniprésentes dans notre vie quotidienne et dans divers domaines. Par exemple, les signaux sonores capturés par un microphone peuvent être représentés sous forme de série temporelle, où chaque point correspond à l'amplitude du son mesurée à un moment précis. De même, les relevés météorologiques, tels que la température quotidienne, sont enregistrés à intervalles réguliers et forment également des séries temporelles. L'analyse de ces séries temporelles peut servir à comprendre les phénomènes, mais aussi prédire de futures conditions ou événements météorologiques. Les données financières, comme les cours des actions, sont également des exemples courants de séries temporelles, car elles montrent comment la valeur d'un actif change au fil du temps (Chatfield 2016).

La Figure 1 présente une série temporelle illustrant les valeurs observées, la tendance, et les cycles périodiques (saisonnalité¹). Les données observées sont représentées par la ligne bleue continue, qui montre les variations des valeurs au fil du temps. La ligne rouge pointillée représente la tendance de la série temporelle. Cette ligne met en évidence la direction générale des données sur la période observée, indiquant si les valeurs tendent à augmenter, diminuer, ou rester stables. Dans ce cas, la tendance montre une légère augmentation constante au fil du temps, ce qui pourrait indiquer une croissance ou une amélioration continue dans les valeurs observées. Les cycles périodiques, ou saisonnalité, sont représentés par la ligne verte en pointillés. Cette ligne montre les fluctuations récurrentes autour de la tendance générale, capturant les variations saisonnières ou cycliques qui se répètent à intervalles réguliers.

¹ Dans le contexte des séries temporelles, la saisonnalité fait référence aux cycles récurrents observés dans les données, qui ne sont pas nécessairement liés aux saisons météorologiques (comme les données paléoenvironnementales traitées dans la suite du mémoire). Ce terme englobe tout phénomène périodique qui se répète à intervalles réguliers, qu'il soit d'origine économique, environnementale, ou autre.




Figure 1 : Exemple de série temporelle avec tendances et saisonnalités

©Abdou Niane

2.1.1 TYPES DE FENÊTRAGE

Dans l'étude de Wang, Wang et al. (2022), le fenêtrage est défini comme une technique utilisée pour segmenter une série temporelle en éléments plus petits et gérables (fenêtres). Chaque fenêtre peut être analysée séparément pour détecter des modèles, des tendances ou des anomalies. Cela facilite l'analyse et la modélisation des données en permettant de traiter des sous-ensembles de la série temporelle. De plus, comme nous le verrons un peu plus loin, certains types d'algorithmes ne gèrent pas les données de taille variables ou encore les données de très grandes dimensions. Ainsi, le fenêtrage peut agir comme solution à certaines problématiques de traitement de données. Nous allons maintenant examiner les principaux types de fenêtrage et leur application dans l'analyse des données temporelles.

1. Fenêtrage explicite

Cette méthode divise la série temporelle en fenêtres de taille fixe, indépendamment du contenu des données. Elle est simple à implémenter et utile pour des tâches de base telles que la détection de tendances et de saisonnalités. Cependant, elle peut ne pas convenir aux séries temporelles avec des événements de durée variable (Quigley, Donnelly et al. 2018).

La Figure 2 présente les séries temporelles des prix d'actions de deux entreprises arbitraires (AAPL et GOOGL), segmentées à l'aide du fenêtrage explicite. Les fenêtres, représentées par des lignes verticales pointillées, divisent les données en segments de taille fixe de 10 unités de temps. Chaque fenêtre peut être analysée séparément pour extraire des caractéristiques telles que la moyenne, l'écart-type ou des motifs spécifiques. Cette méthode de segmentation permet une analyse uniforme des variations des prix au sein de chaque fenêtre.




Figure 2 : Illustration du fenêtrage avec fenêtres de taille fixe

©Abdou Niane

2. Fenêtrage temporel

Les fenêtres sont définies par des intervalles de temps spécifiques (par exemple, horaires, quotidiens ou mensuels). Cette approche est particulièrement adaptée aux séries temporelles influencées par des cycles saisonniers, comme les données météorologiques ou financières (Ermshaus, Schäfer et al. 2023).

La Figure 3 présente une série temporelle segmentée à l'aide du fenêtrage temporel. Les lignes verticales rouges pointillées divisent les données en segments correspondant à des intervalles de 7 jours. Cette méthode de segmentation permet d'analyser les variations saisonnières ou les tendances récurrentes. Elle est aussi très utilisée pour la comparaison de plusieurs séries temporelles à des moments spécifiques. Par exemple, si une action prend 15% de valeur pendant une fenêtre d'un mois, on pourrait vouloir comparer la hausse à celle d'un index afin de mieux mettre en perspective le mouvement de prix.




Figure 3 : Fenêtrage temporel de la série temporelle

©Abdou Niane

3. Fenêtrage basé sur des événements

Cette méthode crée des fenêtres autour de certains événements ou points d'intérêt dans la série temporelle, comme l'activation d'un capteur spécifique dans les données de capteurs intelligents (Quigley, Donnelly et al. 2018). Les fenêtres sont définies par la survenue d'événements particuliers, tels que des pics, des creux, ou des déclenchements de capteurs.

La Figure 4 présente une série temporelle segmentée à l'aide du fenêtrage basé sur des événements. Les zones ombrées en rouge indiquent les fenêtres créées autour des événements significatifs (par exemple, les pics et les creux). Cette méthode permet d'isoler et d'analyser les périodes d'intérêt dans la série temporelle.

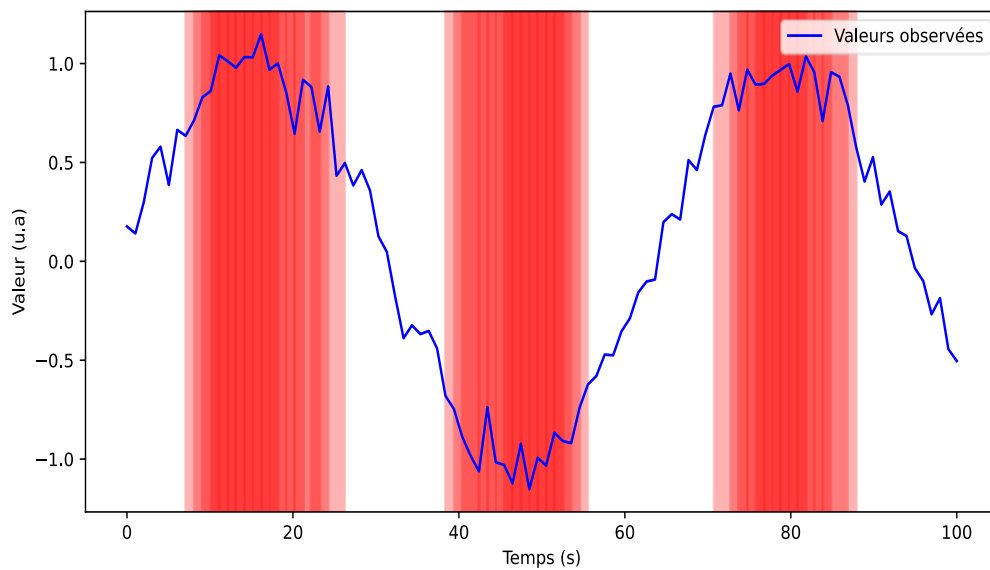


Figure 4 : Fenêtrage basé sur des événements de la série temporelle

©Abdou Niane

4. Fenêtrage dynamique

Contrairement aux approches statiques, le fenêtrage dynamique ajuste la taille des fenêtres en fonction des caractéristiques des données en temps réel. Cela permet une flexibilité accrue et peut améliorer la détection des anomalies et des motifs complexes (Quigley, Donnelly et al. 2018).

La Figure 5 présente une série temporelle segmentée à l'aide du fenêtrage dynamique. Les zones ombrées en rouge indiquent les fenêtres de tailles variables ajustées en fonction de la variance des données. Cette méthode permet une analyse flexible et précise des motifs et des anomalies dans la série temporelle. De plus, elles sont particulièrement adaptées à certaines tâches telles que la reconnaissance des mots dans un signal sonore ou encore la reconnaissance des gestes à partir de centrales inertielles (Keogh, Chu et al. 2004).

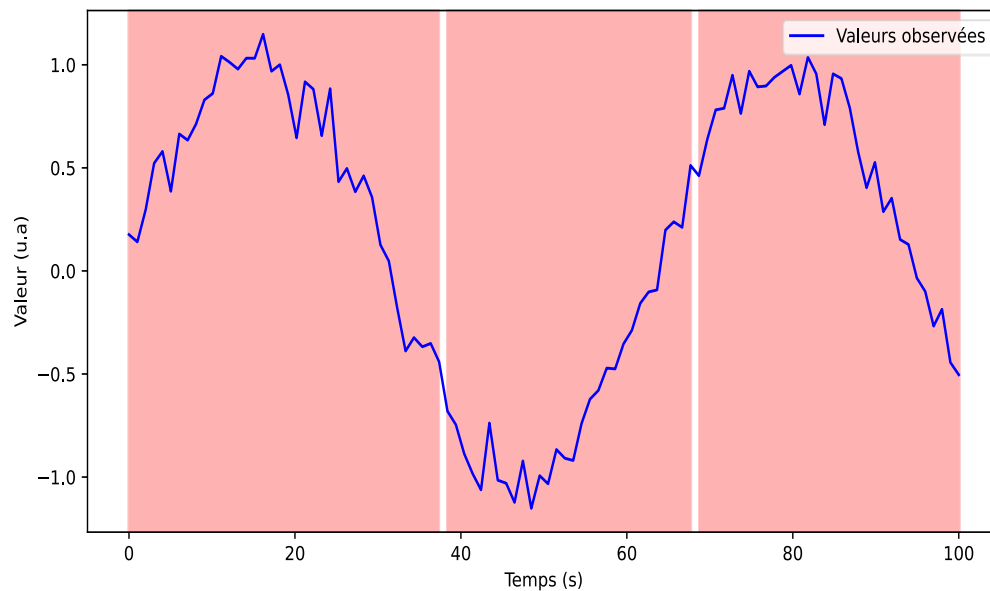


Figure 5 : Fenêtrage dynamique de la série temporelle

©Abdou Niane

Cas d'application du Fenêtrage

Le fenêtrage est largement utilisé dans diverses applications de séries temporelles, notamment dans la reconnaissance des activités humaines dans les habitats intelligents. Prenons l'exemple de l'étude de Quigley, Donnelly et al. (2018) qui met l'accent sur l'application du fenêtrage dans le contexte des habitats intelligents, un domaine spécifique où des capteurs installés dans des maisons intelligentes collectent des données en temps réel pour surveiller les activités humaines.

La reconnaissance des activités humaines est une discipline de l'intelligence artificielle qui vise à identifier et interpréter les comportements humains à partir de données collectées par des capteurs. Elle consiste à analyser les interactions des habitants avec leur environnement et à détecter des motifs récurrents ou anormaux dans les activités quotidiennes. Les techniques de reconnaissance permettent, par exemple, de reconnaître automatiquement des actions telles que manger, dormir ou se déplacer dans la maison, en utilisant des données de capteurs placés dans différents lieux de l'habitat.

Dans cette étude de Quigley, Donnelly et al. (2018), l'objectif principal est de comparer trois techniques de segmentation des données de capteurs dans ce contexte : le fenêtrage temporel, le fenêtrage basé sur des événements de capteurs, et le fenêtrage dynamique. Ces méthodes sont appliquées sur le jeu de données Aruba, un ensemble de données bien établi provenant du projet *Center for Advanced Studies in Adaptive Systems (CASAS)* du laboratoire de recherche de Washington State University, qui comprend des capteurs installés dans une maison intelligente occupée par une seule personne adulte sur une période de sept mois (Cook, Crandall et al. 2013). Les capteurs incluent des détecteurs de mouvement, des capteurs de porte et des capteurs de température, enregistrant diverses activités humaines telles que dormir, préparer des repas, et travailler. Le but est d'évaluer l'efficacité de chaque approche de fenêtrage dans la reconnaissance de ces activités à partir de données capteurs binaires. Le processus de collecte et d'annotation des données permet une comparaison rigoureuse des résultats obtenus par chaque méthode.

Trois approches de fenêtrage ont été appliquées aux données pour évaluer leur efficacité dans la reconnaissance des activités. D'abord, l'approche temporelle, segmente les données en intervalles de temps fixes, ici des fenêtres de 15 secondes. Chaque fenêtre couvre les événements de capteurs activés pendant cet intervalle. Les caractéristiques extraites incluent l'heure du premier et du dernier événement de capteur, ainsi qu'une représentation binaire des capteurs activés, où chaque capteur est représenté par un 1 s'il est activé et par un 0 s'il ne l'est pas. Cette approche permet de capturer les informations de manière uniforme dans le temps, bien qu'elle ne prenne pas en compte les variations dans les périodes d'activité des capteurs. En revanche, l'approche basée sur des événements segmente les données en blocs de 20 événements de capteur. Cette méthode permet de capturer plus précisément les périodes d'activité des capteurs en ajustant la durée des fenêtres en fonction du niveau d'activité observé. Enfin l'approche dynamique s'effectue en deux phases : une phase hors ligne où les caractéristiques des activités sont extraites, telles que le nombre d'activations de chaque capteur, la localisation des capteurs et la durée d'activation ; puis une phase en ligne où les fenêtres sont ajustées en temps réel en fonction des groupes de capteurs les plus pertinents pour chaque activité. Cela permet d'adapter les fenêtres de manière réactive, selon le niveau d'activité des capteurs.

Pour chaque approche, les données de l'étude de Quigley, Donnelly et al. (2018) ont été classifiées à l'aide de la bibliothèque LibSVM. Une validation croisée a été employée pour évaluer les performances des méthodes. Les données ont été normalisées avant chaque classification afin d'assurer la comparabilité des résultats.

Les résultats montrent des différences significatives entre les approches de fenêtrage en termes de précision, de rappel et de F-mesure pour diverses activités. Le Tableau 1 suivant présente une comparaison des performances globales des différentes approches de fenêtrage.

Tableau 1 : Performance des approches de fenêtrage

Fenêtrage	Précision (%)	Rappel (%)	F-Mesure (%)
Temporel	77.20	77.20	75.5
Basé sur des événements	76.39	76.39	74.6
Dynamique	66.65	66.65	65.7

En outre, la F-mesure par activité spécifique est présentée dans le Tableau 2 suivant :

Tableau 2 : F-mesure par activité

Activité	Temporel	Basé sur des événements	Dynamique
Relax	0.883	0.765	0.665
Sleeping	0.820	0.818	0.816
Meal_Préparation	0.734	0.673	0.687
Work	0.656	0.479	0.000
Eating	0.000	0.430	0.000
Leave_Home	0.000	0.473	0.000
Enter_Home	0.000	0.248	-
Bed_To_Toilet	0.000	0.000	0.000
Housekeeping	0.000	0.000	0.000
Other	0.752	0.555	0.660

L'analyse montre que le fenêtrage temporel offre la meilleure F-mesure pour les activités *Sleeping* et *Relax*, mais ne parvient pas à classifier certaines activités telles que *Bed_To_Toilet* et

Housekeeping. Cette approche est avantageuse par sa simplicité et l'uniformité des segments, mais elle peut manquer de contexte pour des activités de courte durée.

Le fenêtrage basé sur des événements de capteurs fournit une bonne classification pour des activités variées et gère mieux les périodes occupées et calmes. Il est flexible et pertinent contextuellement, bien qu'il puisse être influencé par des événements de capteurs non directement liés à l'activité principale.

Bien que le fenêtrage dynamique présente des défis en termes de complexité et de précision, cette approche a le potentiel de s'adapter en temps réel et de mieux détecter les anomalies. Cependant, il peut être désavantagé par des données non annotées ou incorrectement annotées.

Pour des environnements de maison intelligente, selon l'étude, le fenêtrage basé sur des événements de capteurs semble être la meilleure approche en termes de classification d'un large éventail d'activités. Le fenêtrage temporel peut être utilisé pour sa simplicité, tandis que le fenêtrage dynamique nécessite des améliorations supplémentaires pour surmonter ses limitations actuelles et pourrait être exploré davantage pour la détection d'anomalies.

2.1.2 STATISTIQUES SUR LES SÉRIES TEMPORELLES

L'analyse statistique des séries temporelles est essentielle pour comprendre les phénomènes dynamiques observés dans les données. Selon les auteurs de (Shumway et Stoffer 2017), les statistiques des séries temporelles concernent l'analyse des données qui sont collectées séquentiellement dans le temps, visant à identifier les structures sous-jacentes, à modéliser les relations temporelles et à effectuer des prévisions. Cette section présente les principales méthodes statistiques utilisées pour analyser les séries temporelles, en se basant sur des recherches académiques et des applications pratiques.

1. Stationnarité

La stationnarité est un concept clé en analyse des séries temporelles. Une série temporelle est dite stationnaire si ses propriétés statistiques, comme la moyenne et la variance, restent constantes dans le temps. Vérifier la stationnarité est crucial pour garantir des analyses précises. Les tests de stationnarité, tels que le test de Dickey-Fuller augmenté, sont couramment utilisés pour évaluer si une série est stationnaire (Dama et Sinoquet 2021). Des graphiques de statistiques roulantes peuvent également aider à visualiser la stationnarité en traçant la moyenne et la variance sur des fenêtres de temps glissantes.

La Figure 6 ci-dessous présente une série temporelle des températures mensuelles enregistrées dans une ville, accompagnée de la moyenne roulante et de l'écart-type roulant. Les températures sont représentées par la ligne bleue continue, la moyenne roulante par la ligne rouge, et l'écart-type roulant par la ligne verte.

Les résultats du test *Augmented Dickey-Fuller* (ADF) montrent une statistique ADF de 0.6667 et une p-value de 0.9892. Une p-value élevée, bien au-dessus du seuil de signification typique de 0.05, indique que nous ne pouvons pas rejeter l'hypothèse selon laquelle la série temporelle est non stationnaire. En d'autres termes, il est probable que la série temporelle présente une tendance et/ou une variance changeante au fil du temps.

Les graphiques de la moyenne et de l'écart-type roulants montrent également des indications de non-stationnarité. La moyenne roulante (ligne rouge) montre une tendance à la hausse, indiquant que la moyenne des températures augmente avec le temps. Bien que l'écart-type roulant (ligne verte) reste relativement stable, la présence d'une tendance claire dans la moyenne est suffisante pour conclure que la série n'est pas stationnaire.

En conclusion, la série temporelle des températures montre une tendance ascendante claire, ce qui indique une non-stationnarité. Pour appliquer des modèles statistiques qui nécessitent la stationnarité, comme les modèles ARIMA, il serait nécessaire de transformer les données, par exemple en utilisant la différenciation pour éliminer la tendance et rendre la série stationnaire.

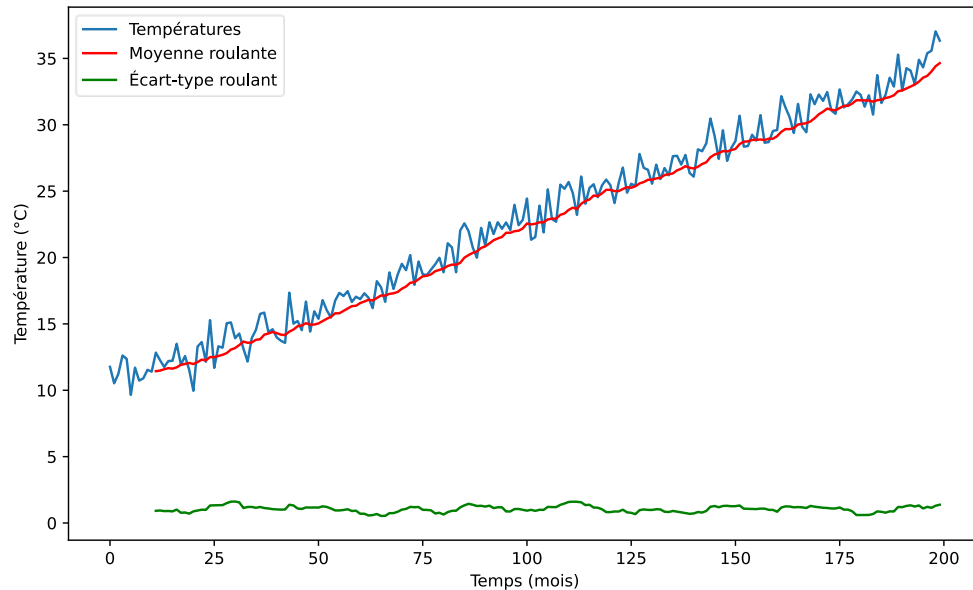


Figure 6 : Série temporelle avec moyenne et écart-type roulants

©Abdou Niane

2. Modèles ARIMA

Les modèles *AutoRegressive Integrated Moving Average* (ARIMA) sont des outils statistiques largement utilisés pour l'analyse et la prévision des séries temporelles stationnaires. Un modèle ARIMA se distingue par sa capacité à combiner trois composants essentiels, chacun apportant une dimension unique à l'analyse des séries temporelles.

Le premier composant, l'auto-régression (AR), est fondamental dans la modélisation des dépendances temporelles. Il permet de capturer la relation entre une observation et un certain

nombre d'observations passées. Dans un contexte commercial, par exemple, les ventes d'un mois donné peuvent être partiellement prédites par les ventes des mois précédents, illustrant ainsi le principe d'auto-régression.

La différenciation (I), deuxième composant du modèle ARIMA, joue un rôle crucial dans la préparation des données. Son objectif principal est de transformer une série non stationnaire en série stationnaire, condition préalable à de nombreuses analyses statistiques. Ce processus implique la soustraction des valeurs précédentes des valeurs actuelles, permettant ainsi d'éliminer les tendances et les variations saisonnières. Par exemple, si une série de ventes montre une tendance à la hausse ou à la baisse, la différenciation aide à supprimer cette tendance, rendant la série plus stable et donc plus propice à l'analyse.

Enfin, le composant de moyenne mobile (MA) complète le modèle en intégrant les erreurs de prévision passées. Comme l'a souligné Winters (1960), ce composant modélise l'erreur en fonction des erreurs passées. Dans la pratique, cela signifie que si les prévisions des ventes du mois précédent étaient inexactes, cette erreur est prise en compte pour ajuster et améliorer les prévisions futures. Ce mécanisme d'auto-correction confère au modèle ARIMA une capacité d'adaptation particulièrement précieuse dans des environnements dynamiques.

Les modèles ARIMA peuvent être adaptés pour inclure la saisonnalité, donnant naissance aux modèles SARIMA (Seasonal ARIMA) qui capturent les variations saisonnières dans les données (Ben Taieb, Bontempi et al. 2012).

La Figure 7 illustre l'application du modèle ARIMA pour la prévision des ventes annuelles d'un produit. Les ventes passées sont représentées par la ligne bleue continue, tandis que les prévisions sont indiquées par la ligne rouge. Le modèle ARIMA a été ajusté aux données historiques des ventes d'un produit sur une période de plusieurs années. Les prévisions montrent une légère variation, reflétant les fluctuations historiques observées dans les ventes passées. Ce modèle permet

d'anticiper les tendances futures et de planifier en conséquence. Les prévisions basées sur le modèle ARIMA sont utiles pour diverses applications commerciales, telles que la gestion des stocks, la planification de la production et la stratégie marketing. En ajustant les paramètres du modèle (ordre de l'auto-régression, degré de différenciation, et ordre de la moyenne mobile), les entreprises peuvent affiner leurs prévisions pour mieux correspondre aux comportements spécifiques de leurs produits et marchés.

L'utilisation du modèle ARIMA pour la prévision des ventes démontre comment les séries temporelles peuvent être efficacement modélisées pour fournir des informations précieuses sur les tendances futures. En combinant les composants AR (Auto-Régression), I (Différenciation) et MA (Moyenne Mobile), le modèle ARIMA offre une méthode robuste pour capturer la dynamique sous-jacente des données temporelles et améliorer la prise de décision stratégique.




Figure 7 : Illustration de la prévision des ventes avec ARIMA

©Abdou Niane

3. Lissage Exponentiel

Le lissage exponentiel est une méthode de prévision des séries temporelles reconnue pour son efficacité, particulièrement lorsqu'il s'agit de traiter des données présentant des tendances ou des composantes saisonnières. Cette technique se décline en plusieurs variantes, telles que le lissage exponentiel simple, le lissage exponentiel double et le lissage exponentiel, chacune étant adaptée à des caractéristiques spécifiques des séries temporelles.

La forme la plus basique, le lissage exponentiel simple, s'applique aux séries sans tendance apparente. Elle attribue des poids décroissants exponentiellement aux observations passées, donnant ainsi plus d'importance aux données récentes. Pour les séries présentant une tendance, le lissage exponentiel double, également connu sous le nom de méthode de Holt, intègre un paramètre supplémentaire, appelé "bêta", pour capturer cette tendance.

Le lissage exponentiel triple, ou méthode de Holt-Winters, représente la forme la plus complète de cette famille de techniques. Comme l'a souligné Gardner (2006), cette méthode est particulièrement adaptée aux séries temporelles exhibant à la fois une tendance et une saisonnalité. La nature de la saisonnalité influence le choix entre une approche additive ou multiplicative de la méthode Holt-Winters. Selon Hyndman et Athanasopoulos (2021), le modèle additif est généralement préféré lorsque l'amplitude des fluctuations saisonnières reste relativement constante au fil du temps, tandis que le modèle multiplicatif est plus approprié lorsque cette amplitude varie proportionnellement au niveau de la série. Pour illustrer l'application pratique de cette méthode, considérons un exemple de prévision de la demande hebdomadaire d'un produit sur une période de quatre ans. En ajustant un modèle de lissage exponentiel triple aux données historiques, il est possible de générer des prévisions pour les 20 semaines suivantes. Dans l'exemple de la Figure 8, une méthode additive est utilisée. Les prévisions montrent une légère variation saisonnière, reflétant les fluctuations historiques observées dans la demande. Ce modèle permet d'anticiper les tendances futures et de planifier en conséquence.




Figure 8 : Prévisions de la demande avec lissage exponentiel triple

©Abdou Niane

4. Méthodes de Sélection Intelligente des Données

L'étude de Gil, Quartulli et al. (2021), apporte une contribution significative au domaine de l'analyse des séries temporelles en se concentrant sur le développement de méthodes statistiques pour la sélection intelligente de données. Cette approche novatrice vise à résoudre un défi majeur dans l'analyse de grandes séries temporelles : la réduction de la taille des ensembles de données tout en préservant les informations essentielles pour l'analyse. Elle permet d'évaluer de manière systématique la pertinence de chaque point de données au sein d'une série temporelle. L'objectif principal est d'identifier et de sélectionner les points de données les plus représentatifs et les plus informatifs, permettant ainsi une réduction significative de la taille des données sans compromettre la qualité de l'analyse subséquente.

La méthodologie développée s'articule autour de trois étapes clés. D'abord, les données des capteurs subissent un pré-traitement rigoureux, consistant à nettoyer les valeurs aberrantes et à imputer les données manquantes. Ensuite, chaque point de données est évalué selon des critères de centralité (comme la moyenne et la médiane), de dispersion (tels que l'écart-type et la variance) et de tendance. Ces mesures sont ensuite combinées pour calculer des scores de pertinence. Enfin, les points de données présentant les scores les plus élevés sont sélectionnés, car ils sont jugés comme étant les plus représentatifs et informatifs pour l'analyse.

La Figure 9 illustre l'application de méthodes de sélection intelligente des données pour des capteurs environnementaux dans une serre. Les données de température et d'humidité sont représentées respectivement par les lignes bleu clair et orange. Les points rouges et bleus indiquent les données sélectionnées en fonction de leur pertinence, avec les points rouges représentant les données de température et les points bleus représentant les données d'humidité. La figure montre que les points sélectionnés (indiqués par les marqueurs rouges et bleus) représentent des fluctuations importantes dans les données de température et d'humidité. En utilisant cette méthode de sélection intelligente, il est possible de réduire la taille des ensembles de données tout en conservant les informations clés nécessaires pour une analyse approfondie.

Cette approche de sélection intelligente des données permet d'optimiser les ressources de stockage et de calcul tout en assurant que les analyses effectuées restent précises et informatives. En mettant l'accent sur les points de données les plus pertinents, les chercheurs et les analystes peuvent se concentrer sur les éléments cruciaux des séries temporelles sans compromettre la qualité des résultats.

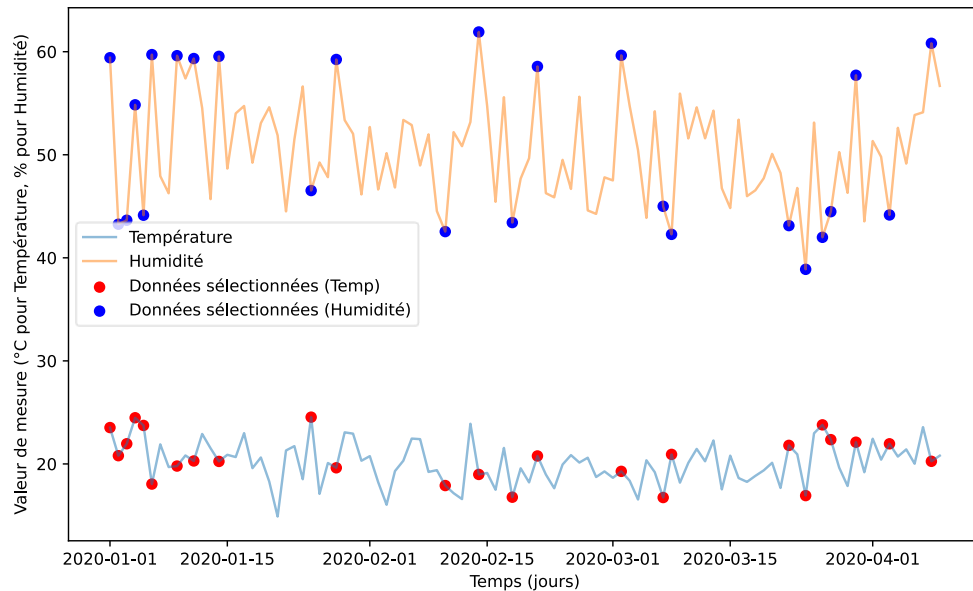


Figure 9 : Sélection intelligente des données de capteurs

©Abdou Niane

2.2 APPRENTISSAGE AUTOMATIQUE

Pour l'analyse et le traitement des séries temporelles, l'apprentissage automatique se positionne en complémentarité avec les analyses statistiques. En effet, ce domaine ne nécessite pas d'hypothèses aussi fortes telle que la stationnarité des données et permet de créer des modèles, certes plus complexes, mais aussi beaucoup plus puissants. Selon Jordan et Mitchell (2015), l'apprentissage automatique est défini comme : *"une approche de l'intelligence artificielle qui se concentre sur le développement de techniques permettant aux systèmes informatiques d'apprendre à partir de données. L'objectif est de développer des algorithmes et des modèles qui peuvent s'améliorer automatiquement avec l'expérience, en identifiant des motifs et des relations complexes dans les données"*. L'apprentissage automatique est généralement divisé en trois grandes catégories selon le type de rétroaction utilisé pour générer le modèle:

- **Apprentissage supervisé** : Dans ce type d'apprentissage, le modèle est formé sur un ensemble de données d'entraînement étiquetées, ce qui signifie que chaque exemple d'entraînement est associé à une sortie correcte appelée la vérité terrain (*ground truth*). Le but est de permettre au modèle de prédire la sortie correcte pour de nouvelles données en apprenant à partir des exemples fournis. Les techniques courantes incluent la régression et la classification (Bishop 2006).

Par exemple, un modèle de régression linéaire peut être utilisé pour prédire le prix des maisons en fonction de caractéristiques telles que la superficie et le nombre de chambres. La Figure 10 ci-dessous montre les résultats de la prédiction des prix des maisons. Les points de données sont représentés en bleu, et la ligne de régression est représentée en rouge pointillé. L'équation de la ligne de régression est également annotée sur le graphique. La ligne de régression montre comment le modèle ajuste les données pour prédire les prix des maisons en fonction de leurs caractéristiques. Les prédictions alignées sur la ligne de régression indiquent une bonne performance du modèle pour les données de test.

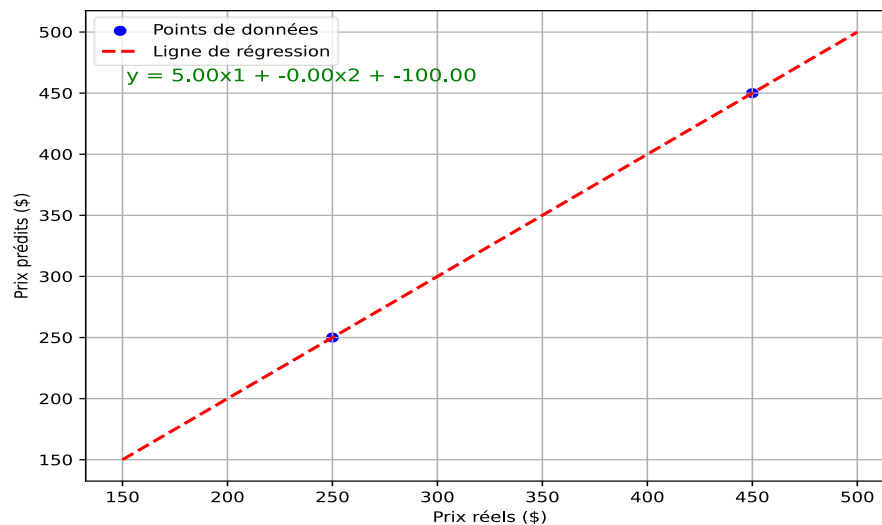


Figure 10 : Prédications de prix de maisons avec régression linéaire

- **Apprentissage non supervisé** : Contrairement à l'apprentissage supervisé, les données d'entraînement dans l'apprentissage non supervisé ne sont pas étiquetées. Le modèle tente de découvrir des structures ou des modèles cachés dans les données. Les techniques courantes incluent le regroupement (*clustering*) et l'analyse en composantes principales (PCA) (Hastie, Tibshirani et al. 2009).

Un exemple courant est le *clustering K-means* utilisé pour segmenter des clients en groupes similaires en fonction de leur revenu et de leurs dépenses. La Figure 11 ci-dessous illustre le regroupement des clients en trois clusters distincts.

Chaque point représente un client, et les couleurs indiquent à quel cluster le client appartient. Par exemple, les clients avec des revenus et des dépenses plus élevés sont regroupés ensemble, tandis que ceux avec des revenus et des dépenses plus faibles forment un autre groupe. Les légendes des clusters et les différentes couleurs permettent de visualiser clairement les segments de clients.




Figure 11 : Clustering de clients avec K-means

- **Apprentissage par renforcement** : Dans cette approche, un agent apprend à prendre des décisions en interagissant avec un environnement dynamique. Il reçoit des récompenses ou des pénalités en fonction des actions qu'il entreprend, et son objectif est de maximiser le total des récompenses reçues au fil du temps. Les techniques courantes incluent les méthodes de Monte Carlo et les algorithmes de différence temporelle (Sutton et Barto 2018).

Un exemple typique est un agent qui effectue une action sur l'environnement, cette action est interprétée en une récompense et une représentation du nouvel état, et cette nouvelle représentation est transmise à l'agent.




Figure 12 : Processus de l'apprentissage par renforcement

©Abdou Niane

En résumé, l'apprentissage automatique offre une multitude de techniques pour extraire des informations significatives à partir de données et développer des systèmes intelligents capables de s'adapter et de s'améliorer avec le temps. Ces techniques sont essentielles dans de nombreux domaines, y compris la reconnaissance de formes, la prévision de séries temporelles,

et la prise de décision autonome. De plus, ces techniques permettent souvent de découvrir des tendances et des motifs au sein de données complexes qui ne sont pas facilement identifiables d'un œil humain. Certaines techniques d'apprentissage automatique avancées sont si puissantes qu'on les dit *Turing Complete* ; capable d'apprendre en théorie n'importe quelle fonction mathématique (Pérez, Marinković et al. 2019).

2.2.1 APPLICATIONS DE L'INTELLIGENCE ARTIFICIELLE EN ARCHÉOLOGIE

L'application de l'apprentissage automatique en archéologie a révolutionné la manière dont les archéologues analysent les données et découvrent de nouvelles informations. Les techniques d'apprentissage automatique permettent d'analyser des volumes de données massifs, d'identifier des motifs cachés et de faire des prédictions précises. Voici quelques-unes des principales applications de l'apprentissage automatique en archéologie :

2.2.1.1 DÉTECTION DE SITES ARCHÉOLOGIQUES

L'application de l'apprentissage automatique à la détection de sites archéologiques représente une avancée significative dans le domaine de l'archéologie. Cette approche novatrice, qui utilise des données satellitaires et de télédétection, permet aux chercheurs d'identifier des caractéristiques spécifiques indiquant la présence de sites archéologiques cachés sous la végétation ou le sol. Une étude particulièrement pertinente dans ce domaine est celle menée par Orengo, Conesa et al. (2020), qui ont développé une méthode innovante pour automatiser la détection de monticules archéologiques dans les images satellitaires.

L'étude d'Orengo, Conesa et al. (2020), s'est concentrée sur le désert de Cholistan au Pakistan, utilisant une approche basée sur l'apprentissage automatique pour détecter des monticules archéologiques. Leur méthodologie a intégré des données satellitaires multispectrales et radar à

synthèse d'ouverture (SAR) multitemporelles pour créer une image composite, qui a ensuite été analysée à l'aide d'un algorithme de classification par forêt aléatoire (*random forest*).

Le processus a débuté par la collecte de données, utilisant des images radar à synthèse d'ouverture (SAR) de *Sentinel-1*² et des données multispectrales de *Sentinel-2*. Ces données ont été traitées via la plateforme *Google Earth Engine (GEE)*, offrant une infrastructure puissante pour le traitement de grandes quantités de données géospatiales. Les données satellitaires ont ensuite subi plusieurs étapes de prétraitement, incluant la calibration radiométrique, la correction terrain et le masquage des nuages pour les images multispectrales, étapes cruciales pour assurer la qualité et la comparabilité des données.

Une image composite multitemporelle a été créée en utilisant les valeurs médianes des différentes images disponibles, une technique qui réduit le bruit radar et stabilise les variations dues aux conditions atmosphériques ou aux changements saisonniers. Pour la classification, les chercheurs ont sélectionné 25 sites de monticules connus comme données d'entraînement et de validation. Un modèle de *random forest* composé de 128 arbres a été entraîné pour classifier les signatures spectrales des monticules, exploitant la capacité de ces algorithmes à gérer des données hétérogènes et à capturer des interactions complexes entre les variables.

Après l'entraînement, le modèle a été appliqué pour produire une carte de probabilité indiquant la présence de monticules archéologiques, utilisant un seuil de probabilité de 0.55 pour différencier les monticules des autres types de sol. Cette approche a permis d'identifier 337 clusters probables de monticules archéologiques, dont seulement 71 correspondaient aux sites connus enregistrés par des enquêtes antérieures. Les nouveaux monticules détectés présentaient des caractéristiques

² Sentinel-1 et Sentinel-2 sont des satellites du programme Copernicus de l'Agence spatiale européenne (ESA). Sentinel-1 est équipé d'un radar à synthèse d'ouverture (SAR) qui permet d'obtenir des images en toutes conditions météorologiques et d'éclairage, de jour comme de nuit, ce qui est particulièrement utile pour la surveillance des changements de surface. Sentinel-2, quant à lui, dispose de capteurs multispectraux qui capturent des images dans diverses bandes de longueurs d'onde, ce qui est essentiel pour analyser la végétation, les eaux et d'autres caractéristiques environnementales.

similaires à celles des monticules connus utilisés comme données d'entraînement, et beaucoup étaient situés dans des zones précédemment inaccessibles.

Les résultats obtenus ont montré une justesse élevée dans la classification des monticules archéologiques, surpassant les méthodes traditionnelles de détection visuelle. Cette étude a révélé une extension significative des sites archéologiques vers le sud et l'est du désert de Cholistan, une zone auparavant considérée comme marginale pour la civilisation de l'Indus. Les sites détectés variaient en taille, certains dépassant 30 hectares, suggérant la présence de centres urbains potentiels.

2.2.1.2 ANALYSE BIOMÉDICALE BASÉE SUR LES COMMUNAUTÉS MAMMIFÈRES

L'application de l'apprentissage automatique pour l'analyse biomédicale des communautés de mammifères offre des perspectives prometteuses pour les études paléoenvironnementales. Linchamps, Stoetzel et al. (2023), ont développé une nouvelle approche pour l'inférence bioclimatique basée sur les communautés de mammifères en utilisant des modèles de régression d'apprentissage automatique. Cette méthode permet de reconstituer les environnements passés en analysant les fossiles de mammifères à partir de la composition de la communauté faunique.

L'approche adoptée s'appuie sur des données modernes concernant la distribution des espèces et des variables bioclimatiques afin d'entraîner divers modèles de régression. Les données bioclimatiques ont été extraites de la base de données Worldclim 2.1, incluant 19 variables telles que les températures moyennes, minimales et maximales, ainsi que les précipitations. Parallèlement, la distribution des espèces de rongeurs à travers l'Afrique a été obtenue à partir de cartes de distribution et de la base de données de l'Union Internationale pour la Conservation de la Nature (UICN).

Les données bioclimatiques et de distribution des espèces ont ensuite été intégrées dans un ensemble unique. Une grille de 10x10 km couvrant le continent africain a été établie, chaque cellule

de la grille étant annotée avec la présence ou l'absence de chaque espèce de rongeur, ainsi que les valeurs bioclimatiques correspondantes. Cette combinaison de données a permis de tester plusieurs algorithmes de régression, y compris la régression linéaire multiple (MLR), la régression élastique net (ELASTIC), la régression RIDGE, la régression LASSO, la régression par forêt aléatoire (*Random Forest*), les arbres extrêmement randomisés (EXTRA), le *gradient boosting* (XGBOOST), et les réseaux de neurones artificiels (NNET). Parmi ces modèles, la forêt aléatoire (RF) a montré les meilleures performances.

Pour évaluer les performances des différents modèles, une validation croisée géographique a été réalisée, partitionnant les données en ensembles d'entraînement et de test tout en minimisant l'autocorrélation spatiale. Les performances ont été mesurées à l'aide de l'erreur quadratique moyenne (RMSE) et du coefficient de détermination ajusté (aR^2).

Les résultats montrent que les modèles de forêt aléatoire ont surpassé les autres modèles en termes de performances prédictives. Par exemple, pour l'évapotranspiration (ET), le modèle RF a obtenu un RMSE de 564.32 et un aR^2 de 0.98, tandis que pour la température moyenne annuelle (bio1), le RMSE était de 0.93 avec un aR^2 de 0.93. D'autres modèles comme le XGBOOST et les réseaux de neurones ont également montré des performances solides avec des RMSE de 552.13 et 660.14 pour ET, et des aR^2 de 0.98 et 0.90 respectivement.

En revanche, les modèles linéaires tels que la régression linéaire multiple et la régression RIDGE ont montré des performances nettement inférieures. Par exemple, la régression linéaire multiple a obtenu un RMSE de 931.27 pour ET, avec un aR^2 de 0.95, et un RMSE de 1.38 pour bio1, avec un aR^2 de 0.85. Le modèle le moins performant était la régression par moindres carrés partiels (PLS), avec des RMSE de 1195.3 pour ET et 1.64 pour bio1, ainsi que des aR^2 de 0.92 pour ET et 0.78 pour bio1. Le Tableau 3 suivant offre un aperçu de la comparaison des performances des modèles.

Tableau 3 : Aperçu de la comparaison des performances des modèles

Modèle	RMSE (ET)	RMSE (bio1)	RMSE (bio2)	RMSE (bio3)	RMSE (bio4)	aR ² (ET)	aR ² (bio1)	aR ² (bio2)	aR ² (bio3)	aR ² (bio4)
MLR	931.27	1.38	0.88	2.87	52.21	0.95	0.85	0.86	0.95	0.95
ELASTIC	928.37	1.38	0.87	2.87	52.32	0.95	0.95	0.96	0.95	0.95
PLS	1195.3	1.64	1.12	3.78	68.83	0.92	0.78	0.76	0.91	0.92
RF	564.32	0.93	0.61	1.84	30.71	0.98	0.93	0.93	0.98	0.98
EXTRA	562.81	1.01	0.60	1.85	30.72	0.98	0.92	0.93	0.98	0.98
XGBOOST	552.13	1.02	0.63	1.85	30.77	0.98	0.92	0.93	0.98	0.98
NNET	660.14	1.13	0.66	1.91	32.37	0.98	0.90	0.92	0.98	0.98

Ces résultats montrent que les modèles d'apprentissage automatique, en particulier la forêt aléatoire, constituent des outils puissants pour reconstituer les conditions paléoenvironnementales à partir des fossiles de mammifères. Cette approche prometteuse pourrait également être étendue à d'autres ensembles de données, enrichissant notre compréhension des changements écosystémiques au cours du temps.

2.2.1.3 DÉTECTION D'ANOMALIES DANS LES DONNÉES SÉDIMENTAIRES

L'analyse des sédiments par des techniques d'apprentissage automatique, telles que la détection d'anomalies, joue un rôle central dans la reconstruction paléoenvironnementale. Dans l'étude récente menée par Bianchette, Pandey et al. (2023), les auteurs ont appliqué une approche

novatrice utilisant des autoencodeurs, une architecture de réseau neuronal non supervisé, pour détecter des anomalies dans des carottes de sédiments provenant de Laguna Boquita, sur la côte pacifique du Mexique. Cette méthode a permis d'identifier des événements environnementaux passés, révélant des changements dans les environnements de dépôt.

Les chercheurs ont collecté cinq carottes de sédiments et ont utilisé des analyses de perte au feu (LOI) pour évaluer les contenus en eau, en matière organique, en carbonate, ainsi qu'en résidus minéraux. La carotte jugée la plus représentative a été soumise à une analyse par fluorescence X (XRF) afin de mesurer les concentrations d'éléments présents. Ces données ont ensuite été traitées à l'aide d'autoencodeurs, qui compressent les données en une représentation de plus faible dimension et tentent de les reconstruire. L'erreur de reconstruction (RE), qui mesure la différence entre les données originales et les données reconstruites, a été utilisée comme indicateur d'anomalies potentielles. Le principal avantage de l'autoencodeur est qu'il peut être entraîné par auto-apprentissage et donc sans avoir besoin d'annotations comme ce serait le cas pour un modèle supervisé. Des valeurs élevées de RE signalent des anomalies dans les carottes de sédiments, souvent associées à des événements environnementaux tels que des transgressions marines ou des changements dans le niveau d'eau. L'étude a également segmenté les carottes en différentes zones stratigraphiques, en fonction des propriétés sédimentaires et des concentrations d'éléments. Les anomalies détectées ont été comparées à ces zones stratigraphiques pour évaluer leur pertinence environnementale.

Les résultats ont révélé plusieurs événements significatifs dans l'histoire environnementale de la Laguna Boquita. Par exemple, pour la Carotte 1, l'autoencodeur a détecté une transgression marine vers ~5200 ans cal. BP, confirmée par des pics de carbonate et la présence de coquilles dans les couches sédimentaires. Cette carotte présente quatre zones stratigraphiques allant d'un environnement terrestre (~6830 - ~6370 ans cal. BP³) à un lagon arrière (~5170 ans cal. BP à

³ BP signifie *Before Present*, c'est-à-dire (par convention) avant 1950. cal. fait référence à âge radiocarbone calibré.

aujourd'hui). Les carottes 2 à 5 ont également révélé des informations importantes. Dans la Carotte 2, par exemple, bien qu'une seule zone stratigraphique ait été identifiée, composée d'argile brune, l'autoencodeur a détecté de faibles anomalies persistantes à la base. Pour la Carotte 3, composée de trois zones stratigraphiques, des anomalies ont été observées dans les couches de sable et de coquilles, ainsi que dans les sections de tourbe. En ce qui concerne la Carotte 4, des anomalies importantes ont été relevées dans les sections de tourbe, tandis que pour la Carotte 5, les anomalies étaient globalement faibles, avec quelques pics notables près du sommet.

Ces résultats montrent que les autoencodeurs sont des outils puissants pour détecter des changements environnementaux passés dans les sédiments, même lorsque ces changements ne sont pas visibles à l'œil nu. Cependant, certains faux positifs et faux négatifs ont été identifiés, soulignant la nécessité d'améliorer les modèles d'autoencodeurs en intégrant davantage de proxys et en augmentant la diversité des carottes de sédiments utilisées pour l'entraînement des modèles. L'étude de Bianchette, Pandey et al. (2023) propose d'étendre ces travaux en ajoutant de nouveaux proxys, tels que les données XRF, et en affinant les algorithmes d'apprentissage automatique pour réduire les erreurs de détection.

2.2.1.4 CLASSIFICATION DES VERRES ANCIENS

L'analyse de la composition chimique des artefacts en verre ancien représente un autre exemple d'application de l'apprentissage automatique dans le domaine archéologique. Dans l'étude menée par Guo, Zhan et al. (2023), les chercheurs ont utilisé l'algorithme de *Support Vector Machine* (SVM) pour classer avec précision des artefacts en verre ancien en fonction de leur composition chimique. Une particularité notable de cette étude réside dans l'utilisation de l'algorithme du *Slime Mould* (SMA) (Li, Chen et al. 2020), inspiré du comportement des moisissures visqueuses, pour optimiser les paramètres du SVM, ce qui a permis d'améliorer considérablement les performances du modèle.

L'ensemble de données utilisé dans cette étude provenait du concours mathématique universitaire chinois de 2022 et incluait les compositions chimiques de 69 groupes d'artefacts en verre. Chaque échantillon comportait les pourcentages de 14 composants d'oxyde. Afin de garantir l'intégrité des données, un processus rigoureux de prétraitement a été mis en place pour éliminer les valeurs invalides et combler les lacunes dans les données manquantes. Une étape clé de cette méthodologie a été l'équilibrage des classes. Les données présentaient un déséquilibre important entre les classes de verre contenant du potassium et celles contenant du plomb. Pour remédier à ce problème, les auteurs ont appliqué une combinaison des techniques *Synthetic Minority Over-sampling Technique* (SMOTE) (Chawla, Bowyer et al. 2002), et *Edited Nearest Neighbors* (ENN) (Wilson 1972), qui a permis de rééquilibrer l'ensemble de données à 98 échantillons, comprenant 49 échantillons de chaque classe.

Les données ont ensuite été transformées à l'aide de la transformation log-ratio centrée, ce qui a amélioré leur interprétabilité et facilité l'analyse statistique. Le modèle SVM a été entraîné à partir d'un ensemble de données divisé en deux : 60 % pour l'entraînement et 40 % pour le test. L'algorithme du *Slime Mould* a été utilisé pour optimiser les paramètres du modèle SVM en simulant le comportement d'une moisissure visqueuse en quête de nourriture, une technique particulièrement efficace dans ce contexte.

Les résultats obtenus ont montré que le modèle SVM optimisé par l'algorithme SMA surpassait tous les autres modèles testés, y compris l'arbre de décision (DT), la forêt aléatoire (RF) et le SVM optimisé par un algorithme génétique (GA-SVM). Le modèle SVM optimisé par SMA a atteint une justesse de 100 % sur l'ensemble d'entraînement et de 97,50 % sur l'ensemble de test. En comparaison, le modèle GA-SVM a atteint une justesse de 92,50 % sur l'ensemble de test, ce qui illustre la supériorité du modèle optimisé par SMA. De plus, les métriques telles que le rappel et le score F-mesure étaient également meilleures pour le modèle SVM-SMA. Les résultats de comparaison des performances des modèles sont présentés dans le tableau 4 suivant.

Tableau 4 : Comparaison des performances des modèles

Modèle	Justesse (Entrainement)	Justesse (Test)	Rappel	F1-Score
DT	79.3%	80.0%	79.3%	78.8%
RF	94.8%	85.0%	86.4%	86.4%
SVM	81.0%	90.0%	81.0%	79.9%
GA-SVM	100%	92.5%	93.1%	93.0%
SMA-SVM	100%	97.5%	97.7%	97.5%

Ces résultats démontrent que l'optimisation des paramètres du SVM par l'algorithme SMA représente une avancée majeure pour la classification des artefacts en verre ancien. En plus de garantir une précision accrue, cette approche a permis de réduire le temps de calcul, ce qui est essentiel dans le cadre de l'analyse de grands ensembles de données archéologiques.

2.2.2 APPROCHES APPRENTISSAGE PROFOND

L'apprentissage profond est une branche de l'apprentissage automatique qui utilise des réseaux de neurones artificiels multicouches pour apprendre des représentations de données avec plusieurs niveaux d'abstraction. Ces modèles sont capables d'extraire automatiquement des caractéristiques pertinentes à partir de données brutes, sans nécessiter une ingénierie manuelle des caractéristiques (LeCun, Bengio et al. 2015).

Dans le contexte des séries temporelles, plusieurs approches spécifiques d'apprentissage profond ont été développées pour traiter, modéliser et prédire des séquences de données temporelles. Cependant, il est important de noter que ces approches ne sont pas toujours appropriées pour tous les contextes, en particulier lorsque l'objectif principal est l'alignement des séries temporelles (Långkvist, Karlsson et al. 2014).

2.2.2.1 RÉSEAUX DE NEURONES RÉCURRENTS

Les réseaux de neurones récurrents (RNN), et plus spécifiquement les *Long Short-Term Memory* (LSTM), sont conçus pour capturer les dépendances à long terme dans les séquences de données. Ils ont montré une efficacité remarquable dans l'analyse des séries temporelles. Malhotra, Vig et al. (2015) montrent que les LSTM sont particulièrement efficaces pour la prédiction de séries temporelles, ce qui en fait une méthode populaire pour les tâches de prédiction.

Selon Siami-Namini, Tavakoli et al. (2018), les LSTM surpassent souvent les modèles ARIMA traditionnels dans la prédiction des séries temporelles. Cependant, leur utilisation pourrait introduire une complexité inutile et potentiellement biaiser les résultats en favorisant la prédiction au détriment de la synchronisation.

2.2.2.2 TRANSFORMEURS

Les transformeurs sont une architecture révolutionnaire pour le traitement des séquences, principalement utilisés dans des tâches de traitement du langage naturel et de génération de texte. Vaswani, Shazeer et al. (2017) présentent les transformeurs comme une alternative aux réseaux récurrents pour la modélisation de séquences.

Wu, Green et al. (2020) ont démontré l'efficacité des Transformeurs dans la prévision des séries temporelles multivariées. Cependant, ils sont également principalement utilisés pour des tâches de prédiction, de classification et de génération de séquences, plutôt que pour l'alignement des séries temporelles. Leur complexité et leur besoin en grande quantité de données d'entraînement peuvent également limiter leur application dans certains contextes archéologiques ou paléoenvironnementaux où les données peuvent être limitées.

2.2.2.3 AUROENCODEURS POUR LES SÉRIES TEMPORELLES

Les autoencodeurs, une autre classe de modèles d'apprentissage profond, peuvent être appliqués aux séries temporelles pour la réduction de dimensionnalité et la détection d'anomalies. Ils fonctionnent en compressant les données séquentielles en représentations de plus faible dimension, puis en les décompressant pour reconstruire les données originales (Malhotra, Ramakrishnan et al. 2016).

Dans le contexte archéologique, les autoencodeurs pourraient potentiellement être utilisés pour identifier des structures ou des motifs cachés dans les séries temporelles de données paléoenvironnementales ou de détecter des anomalies dans les séquences stratigraphiques qui pourraient indiquer des événements inhabituels ou des perturbations (Chalapathy et Chawla 2019).

Cependant, bien que ces applications soient prometteuses pour certaines tâches d'analyse en archéologie, les autoencodeurs ne sont pas directement adaptés à l'alignement des séries temporelles. Leur utilité principale réside dans la préparation et le prétraitement des données plutôt que dans l'alignement lui-même (Bagnall, Lines et al. 2017).

2.2.3 DISCUSSION

Bien que ces approches d'apprentissage profond soient puissantes pour certaines tâches, elles sont conçues principalement pour la prédiction et la classification, alors que l'alignement des séries temporelles nécessite une approche différente, axée sur la comparaison et la synchronisation des séquences temporelles (Petitjean, Forestier et al. 2016). Compte tenu de ces limitations, les approches traditionnelles d'alignement des séries temporelles, telles que le *Dynamic Time Warping* et ses variantes, restent plus appropriées pour le contexte spécifique de l'alignement des séries temporelles en archéologie. Ces méthodes seront discutées en détail dans la section suivante.

2.3 ALIGNEMENT DES SÉRIES TEMPORELLES

L'alignement des séries temporelles est une technique essentielle pour comparer et analyser des séquences de données qui peuvent varier en vitesse ou en longueur. Le DTW est l'une des méthodes les plus populaires pour accomplir cette tâche. Cette section vise à détailler le DTW, ainsi que ses variantes, en utilisant des exemples tirés d'articles fondamentaux pour illustrer leur application et leurs résultats.

2.3.1 DYNAMIC TIME WARPING

Le DTW est une technique permettant de trouver l'alignement optimal entre deux séries temporelles, même si l'une des séries peut être déformée de manière non linéaire en l'étirant ou en la compressant le long de son axe temporel. Cette déformation permet de trouver des régions correspondantes entre les deux séries temporelles ou de déterminer leur similarité (Salvador et Chan 2007). Il est initialement introduit par Sakoe et Chiba (1978) pour la reconnaissance de la parole. Voici une description détaillée de l'algorithme de base ainsi qu'un exemple (Figure 13) d'alignement de deux séries temporelles avec DTW.

1. Initialisation :

- Soient deux séries temporelles $X = (x_1, x_2, \dots, x_n)$ et $Y = (y_1, y_2, \dots, y_m)$.
- Créez une matrice de coût D de taille $n \times m$ où chaque élément $D(i, j)$ représente le coût d'alignement entre x_i et y_j .

2. Calcul des Coûts Locaux :

- Remplissez la matrice D en calculant le coût local $d(x_i, y_j) = |x_i - y_j|$ pour chaque paire (i, j) .

3. Calcul des Distances Cumulatives :

- Calculez la distance cumulative $D(i, j)$ en utilisant la formule :

$$D(i, j) = d(x_i, y_j) + \min(D(i-1, j), D(i, j-1), D(i-1, j-1))$$

- Cette étape détermine le chemin optimal d'alignement en tenant compte des coûts locaux et des coûts cumulés.

4. Chemin Optimal :

- Le chemin optimal d'alignement est déterminé en remontant la matrice de coût depuis $D(n, m)$ jusqu'à $D(1, 1)$.




Figure 13 : Exemple d'alignement de deux séries temporelles avec DTW.

©Abdou Niane

2.3.2 CAS D'APPLICATION DU DTW

Le DTW a été largement utilisé dans divers domaines pour résoudre des problèmes nécessitant l'alignement de séries temporelles. Voici quelques exemples notables tirés d'articles de recherche, illustrant les approches, méthodologies et résultats :

2.3.2.1 RECONNAISSANCE DE LA PAROLE

Sakoe et Chiba (1978) ont introduit le DTW pour aligner des séquences de paroles de longueur variable afin d'améliorer la reconnaissance automatique de la parole. Le problème principal abordé était l'élimination des variations de vitesse de parole, qui provoquent des fluctuations non linéaires dans l'axe temporel des séquences vocales.

L'approche de Sakoe et Chiba (1978) s'appuyait sur une série d'étapes méthodologiques clés. Premièrement, ils ont extrait les caractéristiques acoustiques des séquences vocales à l'aide d'une banque de filtres passe-bande, couvrant une gamme de fréquences allant jusqu'à 5,9 kHz. Ces sorties filtrées étaient ensuite échantillonnées toutes les 18 millisecondes et numérisées pour être utilisées dans l'algorithme. Une fois les caractéristiques extraites, la normalisation du temps était effectuée en appliquant une fonction de warping non linéaire. Cette transformation de l'axe temporel avait pour but de maximiser la correspondance entre deux séquences vocales, ce qui permettait d'aligner des séquences de différentes longueurs tout en tenant compte des variations dans la vitesse de parole. L'optimisation de cette transformation s'effectuait à l'aide de la programmation dynamique (DP).

Deux variantes de l'algorithme DTW ont été explorées dans cette étude : une version symétrique et une version asymétrique. Dans la version symétrique, les deux axes temporels des séquences étaient transformés pour s'aligner sur un axe temporel commun. La version asymétrique, quant à elle, consistait à transformer l'axe temporel d'une seule séquence pour correspondre à l'autre.

Une autre innovation de cette étude résidait dans l'introduction de contraintes de pente, qui avaient pour but d'améliorer la discrimination entre les mots de catégories différentes en limitant la flexibilité de la transformation temporelle. Ces contraintes empêchaient la création d'alignements irréalistes, tels que des correspondances entre segments courts et segments longs des séquences vocales.

Les résultats de cette étude ont démontré l'efficacité du DTW symétrique, associé à une contrainte de pente de $P = 1$, qui a obtenu les meilleurs résultats en reconnaissance de la parole. Ces conclusions ont été tirées d'expériences portant sur un ensemble de données de mots japonais isolés (des chiffres) prononcés par dix locuteurs masculins, chaque mot ayant été répété six fois. Le taux d'erreur obtenu par cette approche était de 0,3 %, un résultat nettement supérieur aux autres méthodes de reconnaissance de la parole testées à l'époque. Le Tableau 5 suivant regroupe le résumé des résultats de cette étude.

Tableau 5 : Comparaison des Taux d'Erreur de Reconnaissance

Méthodes	Taux d' Erreur (%)
Symmetric DP-Matching ($P = 1$)	0.2
Asymmetric DP-Matching ($P = 1$)	0.3
Velichko et Zagoruyko (1970)	2.0
White et Neely (1976)	0.33
Itakura (1975)	0.4
Méthode Linéaire	0.87

2.3.2.2 ANALYSE D'EXPRESSION GÉNIQUE

L'étude de Aach et Church (2001) se concentre sur l'alignement des séries temporelles d'expression génique pour étudier les processus biologiques qui se déroulent sur le temps. Cette méthode est particulièrement efficace pour cartographier des points temporels entre différentes séries qui ne sont pas synchronisées, mais qui représentent des étapes similaires d'un processus biologique.

Aach et Church (2001) ont appliqué l'algorithme DTW à des séries temporelles d'expression de gènes chez la levure, synchronisées selon différents cycles cellulaires. Ils ont utilisé trois séries temporelles distinctes, synchronisées par le facteur alpha, une mutation *cdc15*, et l'élutriation, chacune avec un nombre différent de points temporels (18, 24, et 14 points respectivement). L'objectif principal était d'aligner ces séries temporelles afin d'identifier les points temporels qui représentaient les mêmes phases du cycle cellulaire, malgré des différences dans la dynamique temporelle propre à chaque méthode de synchronisation.

Avant d'appliquer l'algorithme DTW, les séries temporelles ont été normalisées pour garantir la comparabilité des niveaux d'expression entre les différentes séries. Le DTW a ensuite été utilisé pour créer une carte d'alignement temporel, permettant de synchroniser les états cellulaires correspondants. De plus, une version interpolative du DTW a été explorée pour mieux gérer les différences dans les points de mesure, lorsque les séries étaient échantillonnées à des taux différents.

Les résultats de l'étude ont montré que l'algorithme DTW était capable d'aligner efficacement les séries temporelles, en dépit des différences de durée du cycle cellulaire. Cela a permis d'identifier des points temporels synchrones représentant des phases similaires des cycles cellulaires. Les alignements obtenus ont démontré une correspondance étroite entre les phases des cycles cellulaires après l'application du DTW. En particulier, les auteurs ont constaté que la précision de

l'alignement s'améliorait en utilisant des ensembles de gènes avec une faible variabilité de mesure et un nombre important de gènes, ce qui renforce l'intérêt de l'algorithme pour des analyses biologiques complexes.

2.3.2.3 PRÉVISION DES PRIX DES ACTIONS

Dans le cadre de la prévision des prix des actions, l'algorithme du Dynamic Time Warping a été utilisé dans l'étude de Tsinaslanidis et Kugiumtzis (2014) pour évaluer l'hypothèse des marchés efficaces (*Efficient Market Hypothesis*, EMH). L'objectif principal de cette étude était de tester si les mouvements des prix des actions pouvaient être prédits à partir de modèles historiques en utilisant une approche combinant les points perceptuellement importants (Perceptually Important Points, PIP) et le DTW.

La méthode repose sur l'identification des PIP dans une série temporelle de prix, ces points permettant de diviser la série en sous-séquences dynamiques. Le DTW est ensuite appliqué pour mesurer la similarité entre une sous-séquence cible, correspondant à la période de prédiction, et les sous-séquences historiques. Les sous-séquences les plus similaires sont ensuite utilisées pour prévoir l'évolution future des prix. L'étude a été réalisée sur deux ensembles de données, à savoir les indices boursiers mondiaux, qui comprenaient 18 indices couvrant la période de 2000 à 2012, et le taux de change GBP/USD, pour la période allant de 1971 à 2012. Différentes méthodes de segmentation ont été testées, notamment la segmentation à intervalles constants (CI) et la segmentation utilisant les PIP avec trois mesures de distance différentes : la distance euclidienne (ED), la distance perpendiculaire (PD) et la distance verticale (VD). Les performances des prévisions ont été évaluées à l'aide de deux métriques principales: l'erreur quadratique moyenne normalisée par persistance (NPRMSE), qui mesure la performance du modèle par rapport à un modèle naïf basé sur le dernier prix observé, et la prévision indépendante du changement de direction (IPOCID), qui évalue la capacité du modèle à prédire les changements de direction des prix.

Les résultats obtenus ont montré que, pour les indices boursiers mondiaux, l'approche combinant les PIP et le DTW n'a pas surpassé de manière significative le modèle naïf, ce qui corrobore l'hypothèse des marchés efficaces (EMH). En effet, la majorité des valeurs de NPRMSE étaient supérieures à 1, ce qui indique que le modèle de prédiction n'améliorait pas les prévisions par rapport au modèle de persistance naïf. L'IPOCID était également proche de 50%, reflétant une faible capacité à prédire correctement les changements de direction des prix. En revanche, les résultats étaient plus prometteurs sur le marché des changes (GBP/USD), où les valeurs de NPRMSE étaient souvent inférieures à 1, et l'IPOCID dépassait parfois les 50%, en particulier lorsque la segmentation par PIP était utilisée avec des seuils de similarité élevés. Cela montre que cette approche peut être plus efficace dans certains contextes, comme celui des taux de change, offrant ainsi des perspectives pour des recherches futures.

2.3.3 PRINCIPALES VARIANTES DU DTW

Le DTW a prouvé son utilité dans l'alignement des séries temporelles, mais ses limites en termes de complexité computationnelle ont incité la communauté scientifique à développer plusieurs variantes. Ces adaptations visent à améliorer non seulement l'efficacité, mais aussi la précision de l'algorithme, tout en conservant ses atouts fondamentaux. Parmi ces variantes, certaines se démarquent par leur capacité à offrir des performances optimisées pour des applications à grande échelle. Voici un aperçu des versions les plus notables:

2.3.3.1 FAST DTW

Salvador et Chan (2007) ont proposé FastDTW, une version approximative du DTW standard, qui vise à réduire considérablement la complexité temporelle et spatiale de l'algorithme original. Alors que le DTW traditionnel présente une complexité quadratique en termes de temps et d'espace

($O(n^2)$), FastDTW repose sur une approche multirésolution permettant de calculer un chemin d'alignement proche de l'optimal avec une complexité linéaire ($O(n)$).

L'approche adoptée dans FastDTW commence par un échantillonnage des séries temporelles à une résolution très basse. Un premier chemin d'alignement est alors calculé pour cette résolution réduite. Ce chemin est ensuite projeté sur une résolution plus élevée, où il est affiné pour correspondre davantage à la forme réelle des séries. Ce processus de projection et de raffinement est répété jusqu'à ce que le chemin soit calculé pour la résolution complète des séries temporelles. Les auteurs ont démontré que FastDTW présente une complexité linéaire, ce qui rend cet algorithme particulièrement adapté pour des séries temporelles de très grande taille.

Les performances de FastDTW ont été comparées à d'autres méthodes approximatives, telles que les bandes de Sakoe-Chuba et l'abstraction des données, en termes de précision. Les résultats représentés dans le Tableau 6 ont montré que FastDTW parvient à maintenir une grande précision tout en étant beaucoup plus efficace en termes de temps de calcul.

Tableau 6 : Précision de FastDTW par rapport à d'autres méthodes

Méthode	Erreur (%) (Rayon 30)
FastDTW	0,6
Abstraction des Données	1,8
Bandes de Sakoe-Chuba	9,3

En termes de ressources computationnelles, FastDTW s'est avéré plus rapide que le DTW standard pour des séries temporelles de différentes longueurs. Le Tableau 7 suivant montre les temps de calcul pour des séries temporelles de différentes longueurs.

Tableau 7 : Temps de calcul de FastDTW par rapport au DTW standard

Longueur de la Série (Points)	FastDTW (Rayon 100) (Seconde)	DTW Standard (Seconde)
50 000	60	2 530
100 000	207	7 969
150 000	466	16 567

L'algorithme FastDTW s'est montré capable de produire des alignements presque aussi précis que le DTW classique tout en réduisant considérablement les besoins en temps de calcul et en mémoire. Cela le rend particulièrement utile dans des applications telles que la reconnaissance de la parole, l'analyse des trajectoires et le traitement des données sismiques, où l'efficacité est cruciale pour traiter des volumes de données importants.

2.3.3.2 SHAPE DTW :

Introduit par Zhao et Itti (2016), l'algorithme *Shape Dynamic Time Warping* (shapeDTW) a été développé pour améliorer les alignements temporels obtenus avec le DTW en intégrant des informations locales sur les structures des points temporels. Contrairement au DTW classique, qui aligne les séries temporelles en fonction des distances euclidiennes entre les points individuels, shapeDTW s'efforce de coupler les structures locales similaires, évitant ainsi de correspondre des points ayant des formes locales distinctes.

ShapeDTW utilise une méthode en deux étapes pour l'alignement des séries temporelles. Tout d'abord, chaque point temporel t_i est associé à un descripteur de forme qui encode les informations structurelles des sous-séquences locales. Cela transforme la série temporelle originale en une séquence de descripteurs de forme. Ensuite, l'algorithme applique le DTW pour aligner ces séquences de descripteurs, puis applique le chemin d'alignement obtenu aux séries temporelles d'origine pour obtenir l'alignement final.

Dans la méthodologie, chaque point temporel est représenté par une sous-séquence centrée sur ce point, beaucoup plus courte que la série temporelle globale. Ensuite, plusieurs types de descripteurs de forme peuvent être utilisés pour capturer les informations structurelles locales, tels que la sous-séquence brute, la transformation par ondelettes discrètes (DWT) ou encore la pente. Une fois les descripteurs générés, les séquences sont alignées à l'aide du DTW, en utilisant ces descripteurs comme mesures de similitude.

Les résultats expérimentaux montrent que shapeDTW réduit considérablement les erreurs d'alignement par rapport au DTW classique et à d'autres variantes telles que le derivativeDTW (dDTW) ou le weightedDTW (wDTW). Lors d'alignements de séquences simulées, shapeDTW a obtenu des scores d'erreur d'alignement inférieurs, indiquant une meilleure correspondance avec les alignements de référence. De plus, en appliquant shapeDTW à l'alignement de séquences audio et Musical Instrument Digital Interface (MIDI) converties, l'algorithme a surpassé DTW et dDTW dans la majorité des cas, avec des écarts moyens plus faibles par rapport aux alignements de référence. Lorsqu'il a été utilisé comme mesure de distance dans un classifieur de plus proche voisin, shapeDTW a surpassé DTW sur 64 des 84 jeux de données UCR, avec des améliorations significatives de la précision de classification sur plusieurs ensembles de données.

Ces résultats montrent que shapeDTW améliore non seulement la qualité des alignements temporels, mais aussi les performances de classification, en particulier dans des contextes où la structure locale des séries temporelles joue un rôle crucial.

2.3.3.3 WEIGHTED DTW :

WeightedDTW, introduit par Jeong, Jeong et al. (2011), constitue une avancée significative par rapport au DTW classique, notamment en améliorant la précision des alignements de séries temporelles. Cette amélioration est particulièrement cruciale dans les cas où les différences de phase entre les points d'une série temporelle jouent un rôle essentiel dans la classification précise. Contrairement au DTW standard, qui attribue un poids égal à chaque point sans tenir compte de la différence de phase, WeightedDTW ajuste ces poids, ce qui permet de réduire les distorsions dues aux points aberrants et d'améliorer les performances de classification.

La méthodologie de WeightedDTW repose sur l'introduction de la *Modified Logistic Weight Function* (MLWF), une fonction de pondération conçue pour attribuer des poids en fonction de la différence de phase entre deux points. Cette fonction permet de mieux aligner les points critiques, rendant l'algorithme plus robuste pour la classification de séries temporelles complexes. La MLWF permet également d'ajuster la courbure de la fonction en fonction d'un paramètre empirique g , qui contrôle la pénalisation appliquée aux points ayant des différences de phase plus importantes. L'idée derrière WeightedDTW a été étendue aux dérivées temporelles avec le *Weighted Derivative Dynamic Time Warping* (WDDTW). Alors que DDTW se concentre sur l'alignement des caractéristiques de forme des séries temporelles en transformant les points originaux en dérivées, WDDTW applique des pondérations à ces caractéristiques transformées. Cette méthode permet d'améliorer encore la précision de la classification des séries temporelles en se concentrant sur les formes locales et les dérivées des séquences.

Les résultats expérimentaux montrent que WDTW et WDDTW surpassent les autres techniques, telles que le DTW standard, DDTW, et la *Longest Common Subsequence* (LCSS), sur plusieurs jeux de données issus de l'archive *UCR Time Series Data Mining Archive* (Dau, Bagnall et al. 2019). En termes de performance, WDTW a offert une meilleure précision de classification dans

la plupart des cas, particulièrement dans des applications où la forme et la phase des données sont des critères essentiels. Les résultats sont résumés dans le Tableau 8 suivant.

Tableau 8 : Résumé des performances de classification

Jeu de données	Nombre de Classes	Taille des Données d'Entraînement	Longueur des Séries	WDTW (taux d'erreur)	DTW (taux d'erreur)	LCSS (taux d'erreur)
Synthetic Control	6	300	60	0.002	0.007	0.033
Gun-Point	2	50	150	0.040	0.080	0.027
Swedish Leaf	15	500	128	0.138	0.210	0.122
Two Patterns	4	1000	128	0.000	0.000	0.002
Wafer	2	1000	152	0.002	0.004	0.004

Par ailleurs, l'effet des paramètres, notamment w_{max} et g a été largement étudié. Les résultats indiquent que l'augmentation du paramètre g réduit le taux d'erreur jusqu'à un certain point, après quoi le taux d'erreur augmente à nouveau. Cela démontre la capacité de WeightedDTW à ajuster les niveaux de pénalisation en fonction des besoins spécifiques de l'application, offrant ainsi une flexibilité supplémentaire dans les tâches de classification. Dans l'ensemble, WeightedDTW et WDDTW constituent des variantes puissantes du DTW qui, grâce à leur pondération basée sur la différence de phase, améliorent considérablement les performances dans les tâches de classification et de regroupement de séries temporelles.

2.3.3.4 DERIVATIVE DTW :

Le *Derivative Dynamic Time Warping* (DDTW) a été proposé par Keogh et Pazzani (2001) pour surmonter les limites du DTW classique, particulièrement dans le cas de l'alignement de séries temporelles présentant des différences locales en amplitude, telles que des pics ou des vallées d'amplitudes distinctes. Contrairement au DTW qui aligne les valeurs des points uniquement, DDTW inclut les dérivées des points dans son calcul, permettant ainsi d'obtenir un alignement plus précis des formes locales des séquences. Cette approche aide à éviter les alignements non intuitifs où un seul point d'une série temporelle est associé à un segment complet d'une autre.

Le principe fondamental de DDTW repose sur le calcul des dérivées premières des séries temporelles, ce qui permet de capturer la variation locale, ou la pente, à chaque point. La formule utilisée pour calculer la dérivée d'un point est la suivante :

$$D(q_i) = \left(\frac{(q_i - q_{i-1}) + ((q_{i+1} - q_{i-1})/2)}{2} \right)$$

Cette formule permet d'estimer la dérivée d'un point q_i en prenant la moyenne des pentes de ses voisins immédiats. Cette estimation est robuste aux valeurs aberrantes et donne de bons résultats sur des séries temporelles bruitées, en capturant efficacement les tendances locales.

DDTW suit un processus similaire à celui du DTW classique pour l'alignement des séquences temporelles. Il commence par la construction d'une matrice de coût, où chaque élément (i, j) représente la distance entre les dérivées des points q_i et c_j . Ensuite, l'algorithme trouve le chemin d'alignement optimal en minimisant le coût cumulé, tout en respectant les contraintes classiques de monotonie, de continuité et les conditions aux limites. En termes de complexité et de performance,

DDTW partage la même complexité temporelle que le DTW classique, soit $(O(n^2))$. Cependant, DDTW offre des améliorations significatives en matière de précision d'alignement, notamment dans les cas où les séquences présentent des variations locales en amplitude, comme des pics ou des vallées.

Les résultats expérimentaux obtenus par Keogh et Pazzani ont montré que DDTW réduit de manière significative les alignements non pertinents, également appelés *warping spurious*, par rapport au DTW classique. En testant l'algorithme sur des ensembles de données réelles, tels que *Space Shuttle*, *Exchange Rate*, et EEG, DDTW a démontré une capacité supérieure à éviter les déformations excessives de l'axe temporel causées par des différences locales en Y. Les résultats sont présentés dans le Tableau 9 suivant.

Tableau 9 : Comparaison du Warping Spurious entre DTW et DDTW

Jeu de Données	Warping Moyen (pour DTW)	Warping Moyen (pour DDTW)
Space Shuttle	0.17	0.03
Exchange Rate	0.24	0.04
EEG	0.19	0.03

De plus, lors d'expériences où des déformations artificielles ont été introduites dans des séries temporelles, DDTW a surpassé DTW en trouvant des alignements plus précis et plus cohérents entre les séquences ayant des différences locales en amplitude. Les résultats de la comparaison de l'alignement sont présentés dans le Tableau 10 suivant.

Tableau 10 : Comparaison de l'Alignement Correct entre DTW et DDTW

Hauteur du Bump	Alignement Moyen pour DTW	Alignement Moyen pour DDTW
0.0 (pas de Bump)	0.0043	0.0034
0.1	0.0547	0.0039
0.2	0.1278	0.0053

Ces résultats soulignent la capacité de DDTW à fournir des alignements plus naturels et intuitifs, particulièrement dans des contextes où les séquences temporelles présentent des variations en forme, mais pas nécessairement en valeur. DDTW s'avère donc être un outil puissant dans l'alignement de séries temporelles complexes, là où les algorithmes traditionnels comme le DTW peuvent échouer à capturer les correspondances pertinentes.

2.3.4 DISCUSSION

Le Dynamic Time Warping et ses variantes constituent des outils puissants pour aligner des séries temporelles, offrant une flexibilité importante dans de nombreux domaines. Toutefois, en archéologie, l'utilisation de ces techniques demeure encore peu explorée, malgré leur potentiel indéniable. En effet, le DTW pourrait offrir une solution efficace pour analyser et synchroniser des données stratigraphiques provenant de fouilles archéologiques, qui souvent présentent des variations temporelles et des structures complexes. L'alignement des séries temporelles pourrait faciliter la comparaison de phénomènes contemporains à travers différents sites ou périodes, permettant ainsi une analyse plus fine des dynamiques humaines et environnementales. Il reste à développer des applications spécifiques pour adapter pleinement ces outils aux défis propres à l'archéologie.

2.4 CONCLUSION

Cette revue de littérature a permis de faire un état des lieux des principales techniques liées au fenêtrage et à l'alignement des séries temporelles, en mettant un accent particulier sur le DTW et ses variantes. Ces approches, bien qu'encore inexploitées (à notre connaissance) en archéologie, présentent un fort potentiel pour améliorer la gestion des données complexes et hétérogènes issues des fouilles archéologiques. La capacité du DTW à synchroniser et comparer des séries temporelles offre des perspectives intéressantes pour le traitement des données paléoenvironnementales et archéologiques. Ce chapitre pose ainsi les bases méthodologiques essentielles pour les travaux qui suivront, en soulignant la pertinence de l'application de l'apprentissage automatique et des techniques d'alignement temporel dans le cadre de notre recherche. Dans le chapitre suivant, nous détaillerons comment certaines de ces techniques seront utilisées dans notre méthodologie pour l'alignement des séries temporelles.

CHAPITRE 3

ANALYSE DES SERIES TEMPORELLES DANS L'ARCHEOLOGIE

L'analyse des séries temporelles joue un rôle crucial dans l'interprétation des données archéologiques, permettant de mieux comprendre l'évolution des phénomènes naturels et humains au fil du temps. Ce chapitre est structuré en plusieurs sections, chacune abordant un aspect spécifique de l'analyse des séries temporelles. Tout d'abord, nous présentons le contexte archéologique de l'étude ainsi que les données exploitées. Ensuite, nous décrivons les méthodes employées pour détecter les pointes dans ces séries, une étape clé pour identifier les événements singuliers. Le chapitre se poursuit par une analyse des approches de fenêtrage, qui permet d'améliorer les performances des algorithmes d'apprentissage automatique, en particulier pour la prédiction des tendances temporelles. Enfin, l'alignement des séries à l'aide d'algorithmes tels que DTW est discuté, avec une analyse des résultats obtenus.

Ce mémoire s'inscrit dans une démarche de science des données appliquée à l'archéologie. Une partie de ces travaux a conduit à la soumission d'un article scientifique nommé *Late Mid-Pleistocene hominins fire control inferred from sooty speleothem analysis* actuellement en cours d'évaluation, où nous avons traité des aspects spécifiques comme la détection et le décompte des pointes dans les séries, la gestion des zones de chevauchement entre les scans successifs. Cet article a été soumis à la prestigieuse revue *Journal of Archaeological Method and Theory* pour publication.

3.1 PRESENTATION DU CONTEXTE, DES DONNEES

3.1.1 CONTEXTE

La grotte de Nerja, située dans la région andalouse en Espagne, est un site archéologique majeur datant du Paléolithique supérieur et enregistrant également des occupations plus récentes à

l'Holocène. Ce site est particulièrement renommé pour ses représentations artistiques, paléolithiques. Outre ces peintures, la grotte a également servi comme lieu de sépulture au cours du Néolithique, constituant ainsi un site riche en témoignages archéologiques couvrant plusieurs périodes importantes (Medina-Alcaide, Vandeveldt et al. 2023). La Figure 14 montre la localisation géographique de la grotte de Nerja




Figure 14: Localization geographic of Nerja cave (Málaga, Spain). Source: Instituto de Estadística y Cartografía de Andalucía.

© M^a Ángeles Medina-Alcaide (in : (Medina-Alcaide 2020))

Les charbons trouvés à la surface des sédiments et les dépôts de suie enregistrés dans les spéléothèmes retrouvés dans cette grotte sont des témoins des activités humaines, notamment l'usage du feu pour l'éclairage, nécessaire à l'exploitation des galeries internes de la grotte, loin de la lumière du soleil. Ces dépôts représentent une source précieuse d'information pour comprendre l'occupation humaine dans ce lieu. Les échantillons prélevés dans les différentes salles de la grotte offrent ainsi un aperçu unique de l'évolution de l'environnement et des pratiques humaines au fil des millénaires. La grotte de Nerja est représentée dans la Figure 15 suivante.




Figure 15: Grotte de nerja

©Jullit31, CC BY 3.0 <<https://creativecommons.org/licenses/by/3.0/>>, via Wikimedia

Commons

3.1.2 DONNEES

Les données analysées proviennent de plusieurs échantillons de spéléothèmes collectés dans différents secteurs de la grotte de Nerja, appelés GN16-7 et GN16-8, et préparés sous forme de sections polies. L'échantillon GN16-7 est composé de 4 sections (GN16-7-4 à GN16-7-1). Ces sections ont été analysées à l'aide de la technique LA-ICP-MS, qui permet de quantifier précisément les concentrations d'éléments chimiques (majeurs, mineurs, traces) dans les dépôts de spéléothèmes. Les données sont exportées sous forme de fichiers CSV, que nous avons reçus pour une analyse des cycles chimiques saisonniers (Mg, Sr, Ba, U connus pour leurs fluctuations annuelles) (Nagra, Treble et al. 2017). Le but est d'obtenir un calendrier dans lequel replacer les traces de suie, marqueurs des visites sur le site. Cette approche permettra d'acquérir des données précises sur les cycles d'utilisation du feu et d'autres activités anthropiques liées à l'occupation

humaine dans la grotte. La Figure 16 présente le plan topographique de la grotte de Nerja avec localisation des différents secteurs employés en levé systématique. La stalagmite GN16-8 a été prélevée dans les galeries basses (secteur C) et la stalagmite GN16-7 a été prélevée dans les galeries hautes (secteur M).




Figure 16: Topographic plan of Nerja cave with the localization of the different sectors employed in systematic surveying. Modified from F. RAMÍREZ et al. 1985.

© M^a Ángeles Medina-Alcaide (in : (Medina-Alcaide 2020))

Les scans des échantillons GN16-7-4-scan1 à GN16-7-1-scan1 couvrent l'intégralité de l'échantillon GN16-7, scans orientés de la base au sommet, tandis que l'échantillon GN16-8 a été scanné en une seule fois (GN16-8-scan1). Ces scans permettent de capturer la distribution des concentrations élémentaires dans le temps. Les données obtenues sont sous forme de séries temporelles spatiales. Chaque point de donnée contient des informations sur les concentrations en éléments traces exprimées en parties par million (ppm), ainsi que sur les coordonnées spatiales des points d'échantillonnage. Afin d'illustrer la structure des données analysées, la Figure 17 présente un aperçu des premières lignes du fichier de données de GN16-8, incluant les 10 premières colonnes

sur les 40 au total. La colonne Time [Sec] indique le temps écoulé depuis le début du scan en secondes. Les colonnes suivantes (C13, F19, Na23, Mg24, Mg25, Al27, Si28, etc.) représentent les isotopes mesurés, ici exprimés en coups par seconde (CPS), mesure avant la calibration des données (pour obtenir la concentration de chaque élément en ppm). Chaque mesure correspond à une étape spécifique du scan, partant de la base (zones plus anciennes) et progressant vers le sommet (zones plus récentes) de l'échantillon.

Time [Sec]	C13	F19	Na23	Mg24	Mg25	Al27	Si28	Si29	P31
0.3421	2963227.02	236845.71	192220.87	800.02	200.0	12805.47	71029257.84	1000761.16	82225.46
0.6031	3020608.86	234408.06	178655.11	800.02	200.0	12405.13	71249826.59	970887.42	85443.42
0.8641	3023803.19	227503.5	191613.19	400.01	200.0	13005.64	70877939.08	999693.28	76796.71
1.1252	3010651.43	245787.11	185335.23	0.0	0.0	10803.89	71118951.59	1182675.61	79008.18
1.3862	3012199.68	241518.95	175417.31	600.01	0.0	13606.17	71127889.09	997130.59	84840.0
1.6473	2966127.8	241112.53	174607.98	400.01	0.0	13005.64	71798120.35	1259088.99	73781.58
1.9083	2976769.79	240909.33	170561.93	600.01	0.0	12004.8	71974882.86	1237949.34	76595.67
2.1693	3014611.59	220602.06	185942.66	200.0	0.0	15608.12	71400957.85	1219962.72	71369.92
2.4304	2944452.8	236236.26	183917.99	1000.03	0.0	11804.65	71239101.59	1262600.32	80214.58
2.6914	2996358.86	231361.53	183108.18	200.0	0.0	9002.7	71527007.85	1216666.34	83231.0

Figure 17: Aperçu des 10 premières lignes et colonnes des données

©Abdou Niane

Ces données brutes ont fait l'objet d'une préparation initiale comprenant un nettoyage des données, une imputation des valeurs manquantes et une consolidation des fichiers CSV pour l'échantillon GN16-7. Cette préparation a permis de traiter les séries temporelles spatiales de manière cohérente, facilitant ainsi les étapes d'analyse statistique et d'apprentissage automatique, notamment l'application de techniques de lissage par moyenne mobile pour atténuer le bruit sur les données (en partie le bruit lié aux mesures machine). Les détails complets de ces étapes de préparation seront abordés dans les sections suivantes.

3.2 DETECTION DES POINTES DANS LES SERIES TEMPORELLES

L'identification des pics ou des pointes dans les séries temporelles est une étape importante pour analyser des événements significatifs liés aux cycles annuels dans les spéléothèmes, permettant ainsi d'obtenir un calendrier précis dans lequel replacer le signal anthropique (les visites marquées par des dépôts de suie enregistrés dans les spéléothèmes) et ainsi potentiellement de percevoir des évolutions (Medina-Alcaide, Vandeveld et al. 2023).

Dans cette étude, nous avons appliqué trois approches différentes pour détecter les pics dans les séries temporelles: une méthode basée sur le z-score, la méthode des dérivées pour capter les changements brusques, et l'algorithme `find_peaks` de la bibliothèque SciPy. Dans ces échantillons GN16-7 et GN16-8, nous avons respectivement extrait `data7_new` et `data8_new`, deux ensembles de données formés de quatre caractéristiques Mg24, Sr88, Ba138, et U238 pour simplifier l'analyse et l'affichage des résultats. Ces caractéristiques choisies sont souvent celles qui varient de manière saisonnière. Seul l'ensemble de données `data8_new` a été utilisé pour illustrer les résultats de la détection des pics.

3.2.1 METHODOLOGIE

Avant de procéder à la détection des pics, les données ont été préalablement lissées pour réduire les fluctuations mineures et faciliter l'identification des pics significatifs. Le lissage par moyenne mobile a été appliqué avec une fenêtre de taille 10, permettant d'obtenir une vue plus stable des séries temporelles. Par la suite, nous avons testé plusieurs méthodes afin de voir laquelle pourrait détecter les pics.

La méthode du z-score consiste à normaliser les valeurs de la série temporelle en calculant leur écart par rapport à la moyenne globale de la série, tout en tenant compte de l'écart-type. Cette normalisation permet de détecter les points qui s'écartent significativement des autres valeurs. Les

pics sont identifiés lorsque les z-scores dépassent un seuil prédéfini, indiquant une anomalie statistiquement significative. L'application de cette méthode aux séries temporelles a permis d'identifier des pics dans les séries de concentrations d'éléments traces. Le seuil a été ajusté à 0,2, permettant de capturer des pics potentiellement associés à des événements importants.

La méthode de la dérivée identifie les pics en détectant les changements brusques dans la série temporelle, ces changements étant représentés par les variations rapides de la pente. L'idée est que les pics dans une série temporelle correspondent à des points où la dérivée première atteint un maximum local. Pour cette méthode, une première dérivée a été calculée, et les points où cette dérivée dépasse un certain seuil ont été considérés comme des pics. Cette méthode est particulièrement efficace pour capter des changements brusques et est moins sensible aux petites variations que le z-score.

L'algorithme `find_peaks` de SciPy utilise une approche plus flexible pour la détection des pics, en permettant d'ajuster plusieurs paramètres, tels que la hauteur minimale du pic, la distance entre deux pics successifs et la largeur des pics. Cela permet une meilleure adaptation aux caractéristiques spécifiques de chaque série temporelle. Comme pour le z-score et la dérivée, les séries temporelles des éléments Mg24, Sr88, Ba138, et U238 ont été analysées à l'aide de cet algorithme. Le seuil de détection a également été ajusté à 0,2 pour assurer une comparaison cohérente entre les trois méthodes.

3.2.2 RESULTATS

Les trois méthodes ont permis d'identifier des pics dans les séries temporelles des échantillons GN16-8, mais avec des performances et des sensibilités différentes. La méthode du z-score s'est révélée plus sensible aux petites variations, identifiant un plus grand nombre de pics, y compris des anomalies mineures. Cette méthode est efficace pour détecter une grande variété d'anomalies mais génère également des faux positifs dans certaines conditions. Tandis que la méthode de la dérivée

a permis de capturer des changements brusques dans les séries temporelles, identifiant des pics plus significatifs. Cependant, bien qu'elle ait donné de bons résultats, elle peut parfois manquer des pics subtils ou produire des pics moins pertinents si la série contient beaucoup de bruit. Enfin l'algorithme `find_peaks` a permis une détection plus spécifique des pics les plus significatifs, en tenant compte de la hauteur, de la largeur et de la distance entre les pics. Cependant, les performances de cette méthode dépendent fortement des choix des paramètres définis, tels que les seuils de hauteur, de largeur, ou de distance. En ajustant ces paramètres, il est possible d'affiner la sensibilité et la spécificité de la détection. Cette méthode a offert une meilleure robustesse et une plus grande capacité d'adaptation en fonction des paramètres définis.

Les Figures 18, 19 et 20 illustrent les pics détectés par chaque méthode pour l'élément Sr88, mettant en évidence les différences de sensibilité et de précision entre les approches. Une comparaison des résultats montre que la méthode `find_peaks` est plus robuste pour détecter des pics plus grands et plus espacés, tandis que le z-score capture également des anomalies de moindre importance. La dérivée se situe entre les deux, détectant principalement les changements rapides tout en filtrant les petites fluctuations.




Figure 18: Détection des pics pour Sr88 avec la méthode du z-score

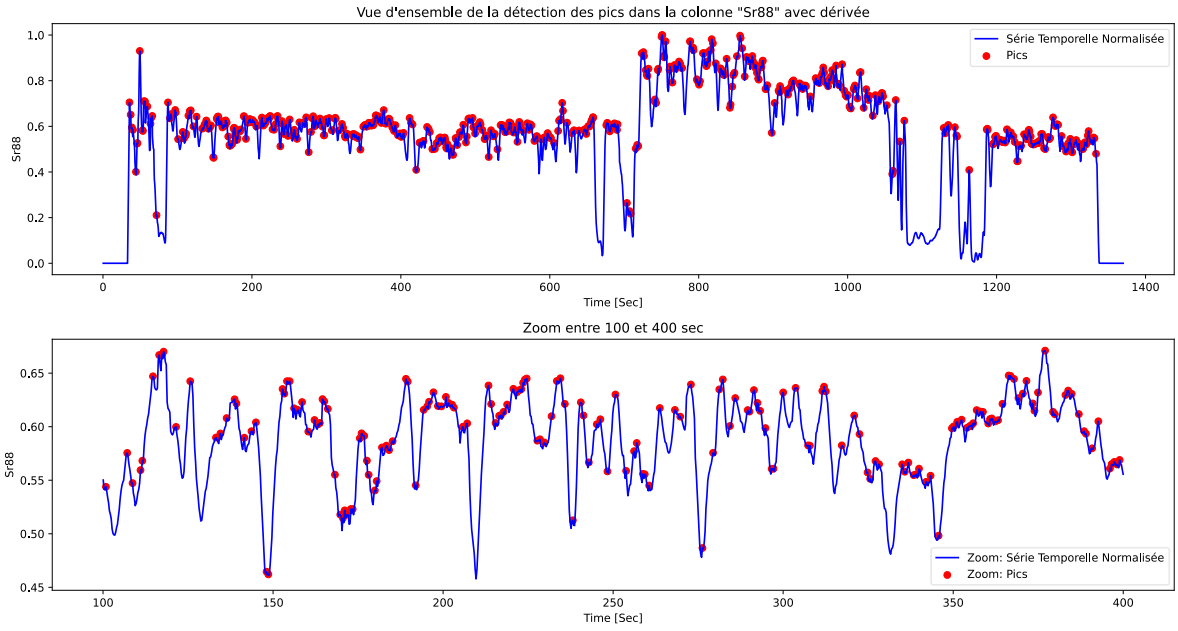


Figure 19: Détection des pics pour Sr88 avec la méthode de la dérivée

©Abdou Niane

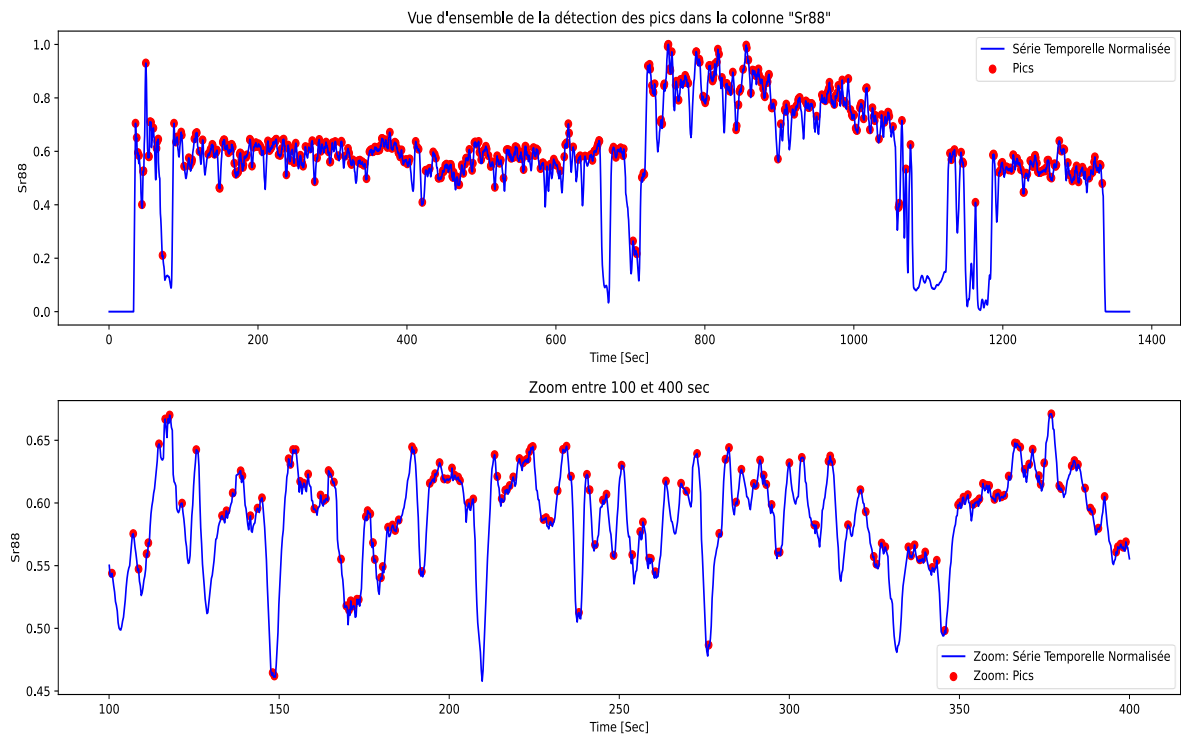


Figure 20: Détection des pics pour Sr88 avec la méthode find_peaks

©Abdou Niane

3.2.3 APPLICATION ET INTERPRETATION ARCHEOLOGIQUE

L'analyse des pics détectés dans les séries temporelles des éléments Sr88, Ba138, Mg24 et U238 pour les échantillons GN16-8 et GN16-7 offre une perspective archéologique significative. Chaque pic correspond potentiellement à une année de dépôt dans la formation des stalagmites, permettant ainsi d'estimer la durée totale de leur formation en années.

Pour l'échantillon GN16-8, 702 pics ont été détectés pour Sr88, 583 pour Ba138, 757 pour Mg24 et 545 pour U238, suggérant une durée de formation comprise entre 545 et 757 ans. En se référant à l'étude de Medina-Alcaide, Vandeveld et al. (2023), le nombre d'occupations calculé pourrait être rapporté à cette durée totale de l'archive pour calculer précisément la fréquence d'occupation du site en nombre d'événements d'occupations par an.

Pour GN16-7 (GN16-7-4 à GN16-7-1), les résultats montrent un total de pics réparti comme suit : 2081 pour Sr88, 1934 pour Ba138, 2090 pour Mg24 et 2039 pour U238. En appliquant une approche similaire à celle de GN16-8, il est également possible de calculer la durée de formation et d'établir un cadre chronologique de résolution temporelle annuelle. Ce cadre pourra intégrer les événements d'occupation humaine marqués par les traces de suie.

Cette méthodologie permet d'établir un cadre chronologique à résolution annuelle, intégrant les événements d'occupation humaine marqués par des traces de suie. Ainsi, la détection des pics dans les séries temporelles des éléments géochimiques des stalagmites offre une application concrète en archéologie.

3.3 FENETRAGE POUR STATISTIQUES ET APPRENTISSAGE AUTOMATIQUE CLASSIQUE

L'analyse des séries temporelles, en particulier dans des domaines tels que l'archéologie, nécessite une segmentation appropriée des données afin de capturer les tendances locales tout en

conservant la structure temporelle globale. Pour ce faire, le fenêtrage s'avère être une technique essentielle, permettant de découper les séries en sous-séquences de taille fixe. Ces fenêtres facilitent non seulement l'analyse statistique, mais elles sont également utilisées comme unités d'entrée pour les modèles d'apprentissage automatique, afin de prédire les valeurs futures des séries temporelles.

3.3.1 FENETRAGE

Dans le cadre de cette étude, le fenêtrage a été appliqué à l'ensemble de données `data7_new`, un ensemble riche et volumineux, choisi en raison de la quantité importante de données qu'il contient, garantissant ainsi une meilleure qualité d'analyse. Le fenêtrage a consisté à diviser les séries temporelles en segments successifs de taille fixe (fenêtres), chacun capturant un ensemble d'observations au fil du temps.

La taille des fenêtres a été soigneusement choisie de manière à capter les tendances locales des séries temporelles sans perdre de vue la continuité des données. Chaque fenêtre est une sous-séquence glissante qui nous permet de comprendre les dynamiques temporelles sur des intervalles définis. L'objectif est de détecter des motifs significatifs à court terme, tout en conservant la possibilité d'entraîner des modèles prédictifs robustes.

La méthodologie utilisée pour le fenêtrage repose sur l'application d'une fenêtre glissante de taille fixe à travers les séries temporelles. Chaque fenêtre comprend un nombre défini d'observations successives, et glisse d'une position à la suivante, garantissant que chaque observation est incluse dans plusieurs fenêtres consécutives. Ce découpage des données en sous-séquences nous permet de modéliser les dynamiques locales, tout en gardant une trace de l'évolution globale des valeurs dans les séries.

Cette approche a permis de transformer l'ensemble de données en une matrice de fenêtres, chacune représentant une sous-partie de la série temporelle. Ces fenêtres serviront par la suite de base à l'extraction de caractéristiques et à l'entraînement des modèles d'apprentissage automatique.

3.3.2 STATISTIQUES UTILISEES

Pour chaque fenêtre extraite, plusieurs statistiques descriptives ont été calculées afin de mieux comprendre les tendances et la structure des données à un niveau local. Les statistiques retenues incluent la moyenne, l'écart-type, la valeur minimale, la valeur maximale, la médiane, ainsi que la somme cumulée des valeurs observées dans chaque fenêtre. Ces statistiques permettent de capturer les aspects clés de la distribution des données dans les fenêtres et fournissent des informations précieuses pour la modélisation et l'analyse des séries temporelles.

La moyenne, qui représente la tendance centrale des valeurs dans chaque fenêtre, fournit une vue d'ensemble sur les fluctuations des données. L'écart-type, quant à lui, reflète la dispersion des valeurs au sein de chaque fenêtre et permet de mesurer la variabilité des données. Les valeurs minimale et maximale permettent de mettre en évidence l'étendue des données dans chaque fenêtre, aidant ainsi à identifier les points extrêmes. La médiane, comme la moyenne, est une mesure de tendance centrale mais elle est moins influencée par les valeurs extrêmes, ce qui permet une analyse plus robuste des fenêtres qui contiennent des valeurs aberrantes. Enfin, la somme cumulée des valeurs dans chaque fenêtre permet d'analyser l'accumulation des données, révélant des tendances de croissance ou de décroissance dans les séries temporelles.

Les graphiques suivants montrent l'évolution de la moyenne, de l'écart-type, et de la somme cumulée à travers les différentes fenêtres extraites des séries temporelles de `data7_new`. Ces visualisations ont pour objectif de mettre en évidence les tendances locales et les périodes d'accumulation rapide des valeurs.

La Figure 21 révèle une variabilité importante dans certaines parties des séries temporelles. En particulier, des pics significatifs de la moyenne et de l'écart-type sont observés dans les premières et dernières sections des données, ce qui pourrait suggérer la présence de phénomènes spécifiques ou de changements de régime. L'augmentation simultanée de ces deux statistiques indique des périodes d'instabilité dans les données, avec une forte fluctuation autour de la moyenne. Les faibles valeurs observées entre 7000 et 12000 dans le graphique, issues des moyennes et écarts-types des fenêtres, reflètent une région de stabilité dans l'ensemble de données initial. Cette stabilité pourrait indiquer une absence de variations significatives dans cette plage, comme observé dans les données brutes.




Figure 21: Évolution de la moyenne et de l'écart-type

©Abdou Niane

La Figure 22 montre une accumulation constante des valeurs dans les fenêtres successives, avec des pics significatifs autour de la fenêtre 12 500. Ces pics peuvent signaler des événements

clés ou des changements brusques dans les séries temporelles, soulignant ainsi des phases d'accumulation rapide des valeurs.

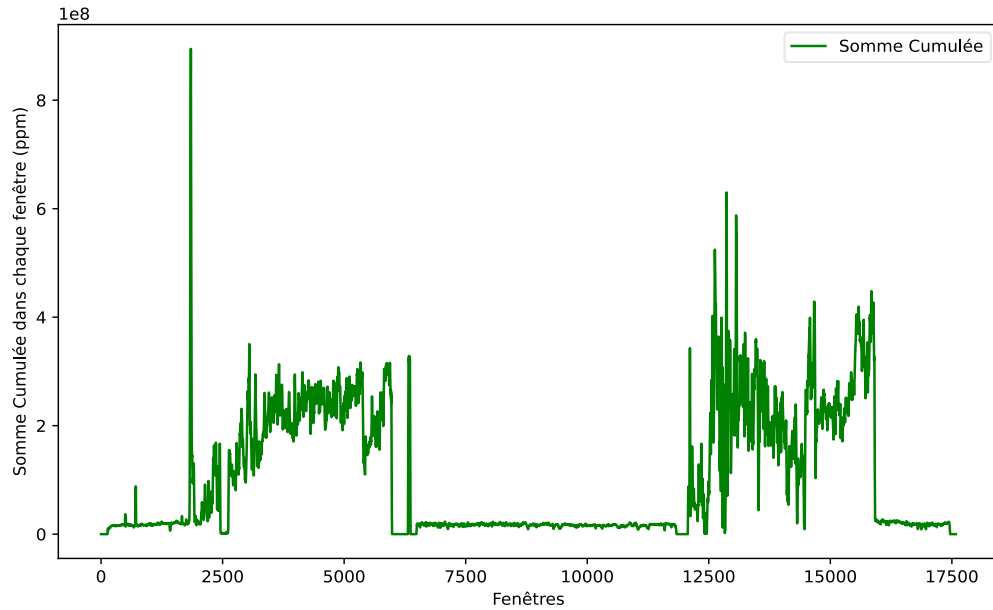


Figure 22: Évolution de la somme cumulée dans chaque fenêtre

©Abdou Niane

3.3.3 PREDICTION DES SERIES TEMPORELLES

La prédiction des séries temporelles est une tâche complexe, particulièrement dans le contexte des données paléoenvironnementales. Cette complexité provient notamment de la nature hétérogène des données, de leur forte dépendance à des processus naturels ou anthropiques qui peuvent varier sur de longues périodes, et de l'influence potentielle du bruit lié aux techniques de mesure. Les motifs temporels des éléments traces, bien qu'informatifs, peuvent être subtils ou masqués par des variations saisonnières ou des anomalies liées aux conditions de dépôt, rendant leur modélisation et leur interprétation plus difficiles. L'objectif de cette section est d'appliquer des modèles d'apprentissage automatique pour prédire la continuation des séries temporelles issues de

l'ensemble de données `data7_new`, en se basant sur les fenêtres extraites précédemment. Plusieurs algorithmes ont été testés pour cette tâche, incluant KNN, Random Forest et XGBoost. Chaque modèle a été entraîné sur les fenêtres de séries temporelles et comparé sur la base de métriques de performance telles que le Root Mean Squared Error (RMSE) et le coefficient de détermination (R^2).

Préparation des données

Pour la prédiction des séries temporelles, l'ensemble de données utilisé est `data7_new` qui est exclusivement constitué des éléments traces Sr88, Ba138, Mg24 et U238 sans inclure les statistiques calculées précédemment (moyenne, écart-type, etc.). Les données ont été segmentées en sous-séquences (fenêtres) grâce à la méthode de fenêtrage décrite précédemment. Pour chaque fenêtre, les valeurs ont été utilisées comme caractéristiques (X) et la dernière valeur de la fenêtre a été utilisée comme la cible (y) à prédire. La taille des fenêtres a été fixée à 10 observations donc Les 9 premières valeurs de chaque fenêtre sont utilisées comme caractéristiques (X) pour l'entraînement, tandis que la 10e valeur est utilisée comme cible (y) à prédire. Après le fenêtrage, les données ont été divisées en ensembles d'entraînement (80%) et de test (20%) afin d'évaluer les performances des modèles. Pour les modèles, les fenêtres ont été aplaties en une seule dimension pour répondre aux exigences des algorithmes classiques de régression supervisée. Les valeurs dans les cibles ont une distribution hétérogène, avec une valeur maximale dans l'ensemble de test atteignant 359.727.708 et une valeur minimale de 0. L'écart-type de l'ensemble de test est d'environ 28.607.830 et la moyenne est d'environ 10.142.770. Ces statistiques montrent une grande dispersion des données, ce qui rend la tâche de prédiction particulièrement complexe.

Résultats des Modèles de Prédiction

Le modèle KNN, avec $k = 5$ voisins, a montré une performance modérée sur cet ensemble de données. Le RMSE du KNN est de 2.423.895, ce qui indique une erreur moyenne **assez élevée**. Le

coefficient de détermination R^2 du modèle est de 0.7289, ce qui montre que le modèle explique environ 72.89% de la variance des données.

En revanche, le modèle Random Forest, qui combine plusieurs arbres de décision, a permis d'améliorer les performances par rapport à KNN. En utilisant 100 arbres et une profondeur maximale de 10, le modèle a atteint un RMSE de 2.061.464. Cependant, le R^2 de Random Forest est de 0.6710, indiquant que le modèle a eu plus de mal à expliquer la variance des données par rapport à KNN, malgré un RMSE plus faible.

Enfin, le modèle XGBoost, une méthode avancée de *gradient boosting*, a offert les meilleures performances de toutes les approches testées. Avec un RMSE de 1.890.372 et un R^2 de 0.9329, XGBoost s'est révélé être le modèle le plus adapté pour cette tâche de prédiction des séries temporelles. Le modèle XGBoost a permis de capturer de manière plus précise les tendances complexes des séries temporelles, notamment en raison de sa capacité à gérer des distributions de données hétérogènes et à corriger les erreurs au fur et à mesure des itérations.

Les résultats obtenus sont résumés dans le Tableau 11. XGBoost a surpassé les autres modèles en termes de précision de prédiction, avec un RMSE plus bas et un R^2 plus élevé, ce qui montre sa capacité à mieux capturer les variations dans les séries temporelles. Cela fait de XGBoost le modèle le plus efficace pour prédire la continuation des séries temporelles dans cette étude.

Tableau 11: Comparaison des performances des modèles

Modèle	RMSE	R^2
KNN	2.423.895	0.7289
Random Forest	2.061.464	0.6710
XGBoost	1.890.372	0.9329

Les Figures 23 et 24 montrent la comparaison entre les valeurs réelles et prédites par le modèle XGBoost. La Figure 23 illustre la performance du modèle sur l'ensemble des observations, tandis que la Figure 24 fait un zoom sur les 100 premières observations pour une analyse plus détaillée. Ces valeurs correspondent à l'ensemble des prédictions réalisées à partir des séries temporelles segmentées et prétraitées et ne représentent pas un élément chimique particulier. La tendance montre que le modèle capture bien les variations dans les séries temporelles.




Figure 23: Comparaison des valeurs réelles et prédites par XGBoost

©Abdou Niane




Figure 24: Zoom sur les 100 premières observations

©Abdou Niane

3.4 ALIGNEMENT DES SERIES TEMPORELLES

Dans cette section, nous nous concentrons sur l'alignement des séries temporelles, en utilisant la technique de DTW pour comparer et synchroniser les données de différents scans. L'alignement est essentiel pour comprendre les relations temporelles entre les séries et pour extraire des informations pertinentes des données archéologiques.

La Figure 25 et 26 sont des exemples de scan de l'échantillon GN16-8 et GN16-7-1, capturés avec la technique LA-ICP-MS. Ces scans montrent les transects des échantillons GN16-8 et GN16-7-1, chaque transect représente une série temporelle spatiale des concentrations élémentaires dans l'échantillon.



Figure 25: Scan GN16-8 réalisé par LA-ICP-MS
 ©Ségolène Vandevelde et Dany Savard




Figure 26: Scan GN16-7-1 réalisé par LA-ICP-MS
 ©Ségolène Vandevelde et Dany Savard

3.4.1 TESTS ET VISUALISATION DES ALIGNEMENTS

Plusieurs méthodes d'alignement des séries temporelles ont été testées afin d'identifier celles qui permettent d'obtenir les meilleurs résultats, en particulier dans le contexte de ces données géochimiques en contexte archéologique. Les paires de séries temporelles reçues et testées incluent notamment GN16-7-1_scan1 et GN16-7-1_scan2, GN16-7-1_scan2 et GN16-7-1_scan3, GN16-8-scan1 et GN16-8-scan2. L'objectif principal était d'examiner les correspondances entre ces séries, qui, bien que présentant des déformations, des condensations ou des chevauchements partiels, devraient être globalement similaires. Parmi ces séries, nous avons décidé de nous concentrer principalement sur la paire GN16-8-scan1 et GN16-8-scan2 (où GN16-8-scan1 devrait être égal à GN16-8-scan2) pour l'analyse détaillée des résultats, bien que des tests similaires aient été effectués sur les autres paires.

Présentation des méthodes d'alignement testées :

La première méthode testée est la DTW classique, qui est couramment utilisée pour aligner des séries temporelles ayant des motifs similaires mais décalés temporellement. DTW permet de mesurer la dissemblance entre deux séries en alignant leurs points de manière à minimiser les écarts entre eux. Nous avons choisi cette méthode pour sa précision et sa capacité à capturer les alignements optimaux, ce qui est particulièrement pertinent dans un contexte où les données (archéologiques) présentent des variations non linéaires dans le temps.

Ensuite, nous avons testé FastDTW, une version approximative de DTW, qui offre des avantages en termes de rapidité pour les grandes séries de données. Cependant, bien que FastDTW ait produit des résultats plus rapidement, nous avons constaté que sa précision était légèrement inférieure à celle de DTW classique, ce qui a conduit à des alignements légèrement moins précis dans certaines zones critiques des séries.

Enfin, nous avons également testé WDTW, une variante pondérée de DTW qui accorde plus d'importance aux alignements temporels en fonction de la distance entre les points. Cette méthode s'est avérée intéressante pour certaines parties des séries, mais les résultats n'ont pas justifié son adoption comme méthode principale, car la pondération ajoutée ne correspondait pas parfaitement aux caractéristiques spécifiques des séries testées.

Visualisation des alignements :

Pour illustrer nos résultats, nous nous concentrons sur la paire de séries GN16-8-scan1 et GN16-8-scan2, qui présentent des motifs similaires mais avec un décalage temporel. Ces deux scans ont été obtenus à partir des mêmes strates, et leur alignement est crucial pour vérifier la correspondance des événements enregistrés. Avant l'alignement, les séries ont été prétraitées par une normalisation Min-Max Scaler et un lissage à l'aide d'une fenêtre mobile pour éliminer les variations brusques et rendre les motifs plus comparables.

La Figure 27 montre les résultats de l'alignement avec la méthode DTW. Les lignes grises qui relient les points entre GN16-8-scan1 et GN16-8-scan2 illustrent les correspondances après alignement. Ces correspondances montrent que malgré les décalages temporels initiaux, les deux séries ont pu être synchronisées avec une précision satisfaisante. Nous avons également zoomé sur certaines sections spécifiques (Figure 28) pour examiner les correspondances locales de manière plus précise. Cette visualisation met en évidence les sections bien alignées, ainsi que les légères divergences dans les zones de transition rapide des données.

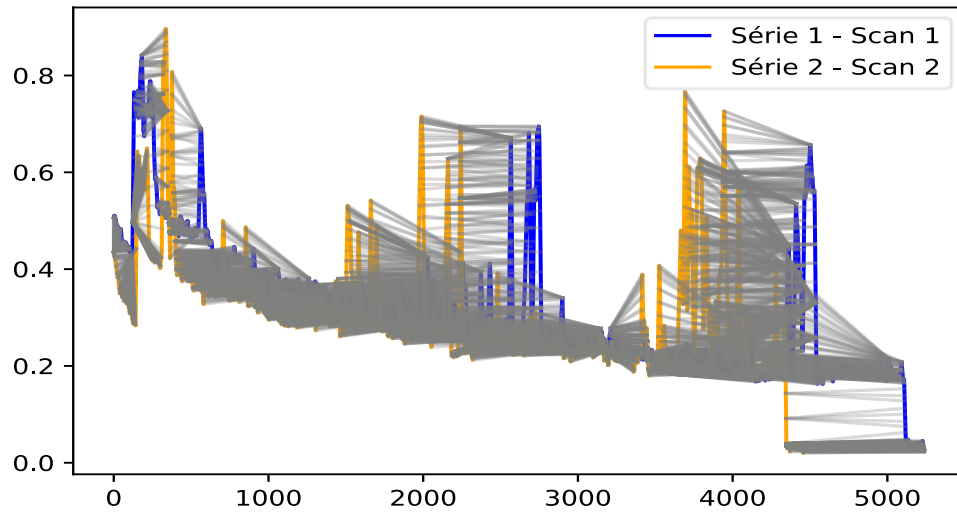


Figure 27: Alignement des séries temporelles avec DTW

©Abdou Niane

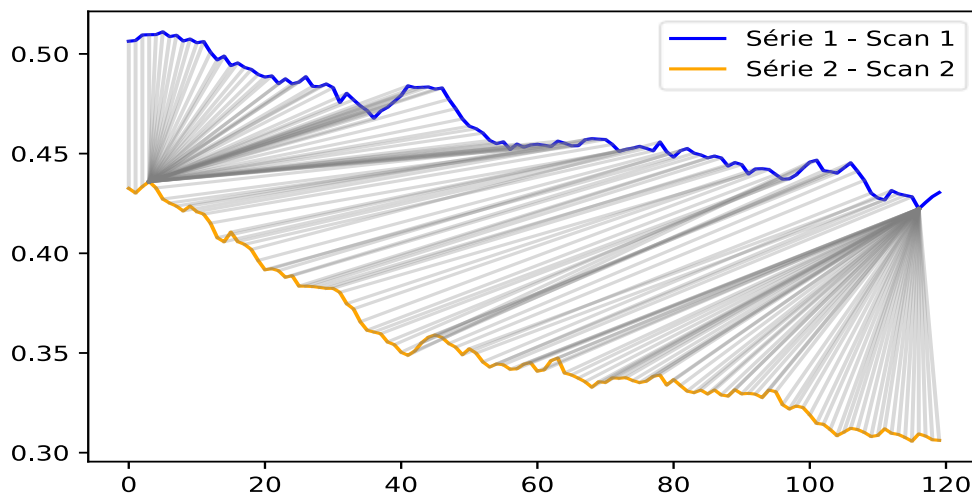


Figure 28: Zoom de l'alignement entre deux points

©Abdou Niane

3.4.2 ANALYSE DES RESULTATS

Avec l'application de l'algorithme DTW, la distance calculée est de 2.72. Cette valeur est relativement faible, indiquant que les deux séries temporelles présentent un bon degré de similarité après alignement. Bien que des différences subsistent, cette distance montre que DTW a réussi à réduire de manière significative les écarts initiaux en synchronisant les motifs communs tout en prenant en compte les décalages temporels. Dans le contexte archéologique, cette distance démontre l'efficacité de l'algorithme pour révéler des correspondances pertinentes entre les séries, tout en laissant une certaine marge pour interpréter les différences restantes. En complément, la différence moyenne absolue après alignement a été calculée et s'est avérée être de 0.0062 pour la paire GN16-8-scan1 et GN16-8-scan2. Cette faible valeur témoigne de la proximité des points correspondants après l'alignement, confirmant ainsi la précision de l'algorithme DTW dans la réduction des écarts entre les séries.

La Figure 29 présente trois étapes importantes de l'alignement des séries temporelles Série 1 (GN16-8-scan1) et Série 2 (GN16-8-scan2) grâce à l'algorithme DTW. Avant l'alignement (séries originales), les séries montraient des différences visibles, avec des pics et des fluctuations non synchronisées. Après l'application de DTW, la série 2 a été alignée pour correspondre à la série 1, révélant des motifs bien plus synchronisés, ce qui témoigne de l'efficacité de l'algorithme dans la réduction des écarts. La synchronisation des événements est désormais plus claire entre les deux séries. Le dernier graphique montre la différence point par point entre les deux séries après alignement. La faible amplitude des écarts, avec des valeurs proches de zéro, confirme que l'alignement a bien fonctionné, avec des écarts résiduels minimes.

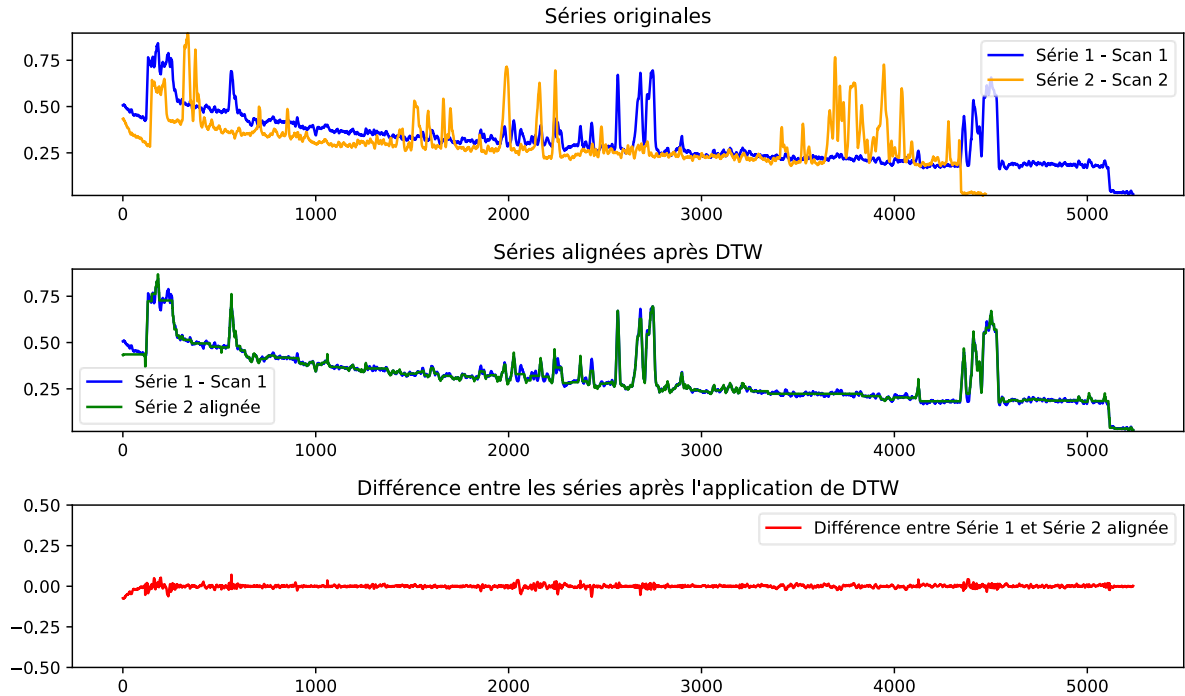


Figure 29: Comparaison des séries avant et après alignement DTW

©Abdou Niane

La Figure 30 présente les séries alignées après l'application du DTW. Cette visualisation montre clairement la synchronisation obtenue entre les deux séries après l'alignement, avec des motifs et des tendances qui sont désormais beaucoup plus proches.




Figure 30: Illustration de la série 1 et de la série 2 alignée

©Abdou Niane

Bien que la plupart des zones aient été alignées avec succès, certaines divergences résiduelles ont été observées dans des sections spécifiques des séries, notamment dans les transitions brusques où les données changent rapidement. Ces divergences peuvent être attribuées aux variations structurelles des séries, ainsi qu'à des différences dans la condensation des données entre certains scans. L'importance de cet alignement réside dans le fait qu'il permet d'identifier des périodes d'activité similaire ou des événements environnementaux.

D'autres paires de séries temporelles ont également été testées, y compris GN16-7-1_scan1 et GN16-7-1_scan2. Ces deux scans présentent des chevauchements partiels où GN16-7-1_scan2 devrait se synchroniser avec la seconde moitié de GN16-7-1_scan1. L'algorithme DTW, en cherchant à minimiser les écarts entre les deux séries, force néanmoins l'alignement sur l'ensemble de leurs points. Cette caractéristique de DTW constitue à la fois un atout, en ce qu'elle permet de capturer les motifs similaires, et une limite, car elle peut introduire des correspondances artificielles dans les sections non pertinentes.

Avec l'application du DTW, la distance calculée est de 3.27. En complément, la différence moyenne absolue après alignement a été calculée et s'est avérée être de 0.15. L'analyse de cette paire a révélé que les motifs dans les sections chevauchantes sont effectivement alignés, tandis que les sections non chevauchantes montrent des écarts plus importants. Ce comportement met en évidence une des limites de l'algorithme DTW dans le contexte de séries temporelles avec chevauchements partiels. Les résultats sont présentés dans la Figure 31 et la Figure 32.

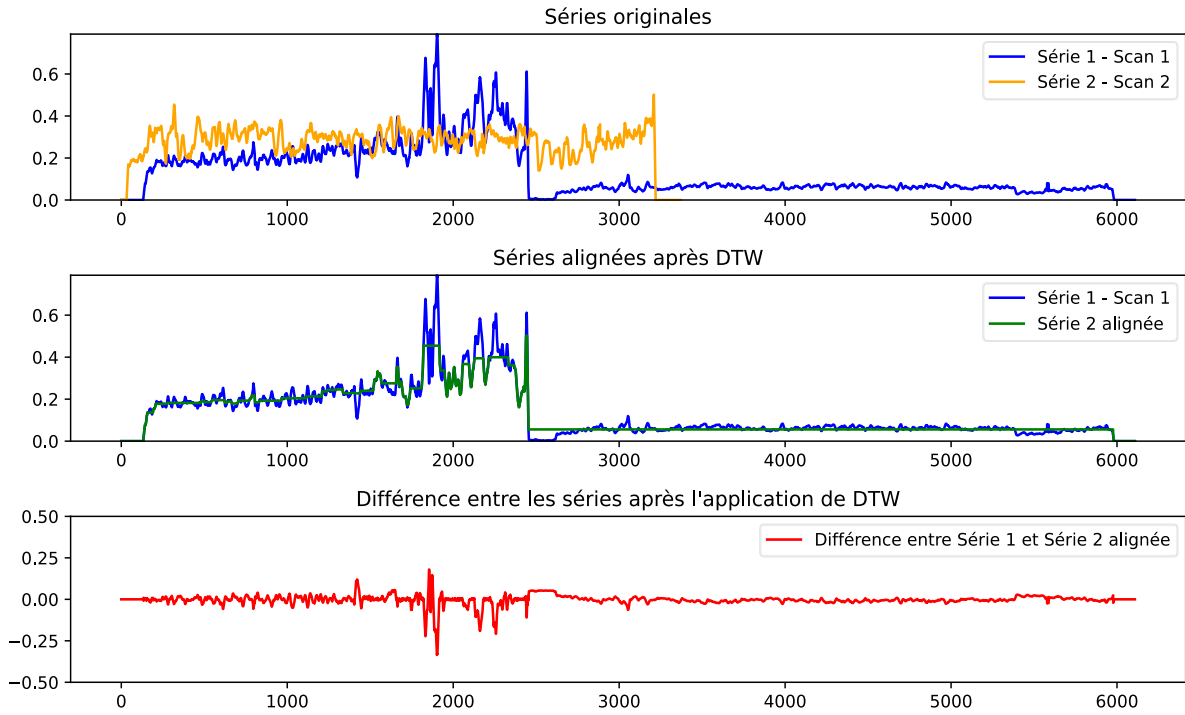


Figure 31: Alignement DTW sur des séries synchronisées partiellement

©Abdou Niane




Figure 32: Illustration de la série 1 et de la série 2 alignée

©Abdou Niane

3.5 CONCLUSION

Ce chapitre a exploré l'analyse des séries temporelles dans un contexte archéologique, en commençant par la présentation du contexte et des données. Nous avons appliqué des méthodologies de détection des pointes pour identifier des variations significatives, suivi d'une approche de fenêtrage pour calculer des statistiques descriptives et effectuer des prédictions. L'alignement des séries, réalisé à l'aide de DTW, a révélé des relations temporelles pertinentes entre les scans, illustrant ainsi la capacité de ces techniques à fournir des compréhensions significatives sur les dynamiques historiques.

CHAPITRE 4 CONCLUSION

Ce chapitre conclut notre étude en récapitulant les principales contributions, les limites rencontrées et les perspectives de travaux futurs. À travers l'analyse des séries temporelles dans le contexte archéologique, nous avons mis en œuvre des méthodologies variées qui ont permis de détecter des motifs significatifs, d'effectuer des prévisions et d'aligner des données provenant de différents scans. En utilisant des techniques telles que la détection de pics, le fenêtrage, l'apprentissage automatique et l'algorithme DTW, nous avons non seulement amélioré notre compréhension des données archéologiques, mais également mis en lumière des relations temporelles cruciales. Ce chapitre vise à synthétiser ces contributions, à reconnaître les limites de notre approche, et à envisager des pistes de recherche futures qui pourraient enrichir encore davantage notre compréhension des dynamiques passées.

4.1 REVUE DES CONTRIBUTIONS

Ce mémoire a apporté des contributions significatives à la compréhension et à l'analyse des séries temporelles dans le contexte archéologique. Tout d'abord, nous avons mis en œuvre des méthodologies robustes pour la détection des points d'intérêt dans les séries temporelles, en utilisant des approches classiques telles que le z-score et des algorithmes de détection de pics de SciPy. Ces techniques ont permis d'identifier efficacement les variations significatives, offrant ainsi des aperçus précieux sur les événements historiques enregistrés dans les données.

Ensuite, la section sur le fenêtrage a permis de calculer des statistiques descriptives essentielles, telles que la moyenne, l'écart-type et la somme cumulée. Ces statistiques ont non seulement enrichi notre compréhension des tendances présentes dans les séries temporelles, mais ont également été fondamentales pour évaluer la performance des modèles d'apprentissage automatique.

Un apport supplémentaire de ce mémoire a été la capacité à prédire la suite des séries temporelles à l'aide de modèles classiques d'apprentissage automatique, tels que *KNN*, *Random Forest* et *XGBoost*. Les résultats de ces prédictions ont été particulièrement encourageants, avec des performances indiquant une bonne précision des modèles.

Enfin, l'utilisation de l'algorithme DTW pour l'alignement des séries temporelles a permis de synchroniser des données avec des décalages temporels, mettant en lumière des relations temporelles essentielles entre les différents scans. Les visualisations fournies dans ce mémoire illustrent non seulement les alignements, mais également la qualité de la synchronisation obtenue, renforçant ainsi l'efficacité de l'approche DTW dans l'analyse des séries temporelles archéologiques.

En somme, ce mémoire a établi un cadre méthodologique solide pour l'analyse des séries temporelles, posant les bases pour des études futures et contribuant à une compréhension plus approfondie des comportements humains et des changements environnementaux à travers le temps.

4.2 LIMITES

Bien que ce mémoire ait fourni des contributions significatives à l'analyse des séries temporelles dans le contexte archéologique, certaines limitations doivent être reconnues. Tout d'abord, la sélection des données peut influencer les résultats, car les séries temporelles analysées proviennent de scans spécifiques. Les caractéristiques des données, telles que leur qualité, leur résolution et leur couverture temporelle, peuvent affecter l'efficacité des méthodes appliquées.

Ensuite, bien que l'algorithme DTW ait démontré son efficacité pour aligner des séries ayant des motifs similaires, il présente des limites lorsqu'il est appliqué à des séries présentant des chevauchements partiels ou des correspondances incomplètes, comme c'est le cas pour GN16-7-1_scan1 et GN16-7-1_scan2. En effet, DTW force l'alignement sur l'ensemble des points des deux séries, ce qui peut introduire des correspondances artificielles dans les sections non chevauchantes.

Cette caractéristique limite sa capacité à capturer avec précision les relations locales dans les séries partiellement synchronisées.

De plus, les résultats obtenus dépendent fortement des paramètres choisis pour les algorithmes, tels que les seuils de détection ou la taille des fenêtres dans le fenêtrage. Une mauvaise sélection de ces paramètres pourrait potentiellement fausser les résultats et limiter la généralisation des conclusions à d'autres ensembles de données archéologiques.

Enfin, ce travail se concentre principalement sur l'alignement des séries temporelles et l'identification des tendances, mais ne traite pas en profondeur d'autres facteurs contextuels, tels que les influences environnementales ou anthropiques, qui pourraient également jouer un rôle dans les variations observées dans les données. L'intégration de ces éléments contextuels dans des études futures pourrait enrichir l'interprétation des résultats et offrir une vue d'ensemble plus complète des dynamiques archéologiques.

4.3 TRAVAUX FUTURS

Les résultats de cette étude ouvrent la voie à plusieurs pistes de recherche qui pourraient approfondir la compréhension des séries temporelles dans le contexte archéologique. Une première direction pourrait consister à multiplier les tests sur un contexte bien connu, en exploitant davantage les données déjà disponibles dans cette étude. Bien que toutes les données n'aient pas été utilisées dans le cadre de ce mémoire, leur inclusion dans des tests supplémentaires permettrait de mieux évaluer la robustesse et les limites des approches méthodologiques, avant de s'étendre à des contextes plus complexes ou variés.

Une autre piste de recherche serait d'étendre ces analyses à des séries temporelles issues d'autres échantillons intra-sites, permettant d'explorer les relations temporelles à l'intérieur d'un même site archéologique. Cela offrirait une base solide pour tester la robustesse des méthodes

d'alignement et de détection des motifs dans des conditions contrôlées. À terme, cette approche pourrait être élargie à des séries inter-sites, ouvrant ainsi la possibilité d'analyser des correspondances temporelles ou des différences entre plusieurs sites archéologiques.

En vue d'une généralisation des résultats obtenus, il serait aussi pertinent d'intégrer des séries temporelles provenant d'autres régions géographiques et de tester les méthodes dans des contextes archéologiques variés. Cette diversification des contextes permettrait d'évaluer l'applicabilité des outils développés et d'adapter les paramètres des méthodes pour répondre aux spécificités de chaque environnement.

De plus, il serait bien d'explorer des techniques d'apprentissage automatique avancées, telles que les réseaux de neurones profonds, pour améliorer les capacités de prédiction des séries temporelles. L'intégration de ces approches pourrait permettre d'exploiter pleinement les structures complexes des données archéologiques et de réaliser des prédictions plus précises sur les comportements humains et les changements environnementaux au fil du temps.

Une autre direction intéressante serait d'analyser les facteurs contextuels qui influencent les variations dans les données, notamment en tenant compte des aspects environnementaux, sociaux et culturels. Cela pourrait enrichir les interprétations des résultats en offrant une vision plus intégrée des dynamiques archéologiques.

Enfin, le développement de nouveaux algorithmes ou l'optimisation des techniques existantes, comme DTW et ses variantes, pourrait améliorer l'efficacité des alignements, notamment dans des situations où les données présentent des déformations plus prononcées ou des bruits significatifs. Ce travail pourrait également inclure la mise en œuvre de méthodes de visualisation avancées pour faciliter l'interprétation des résultats et la communication des découvertes à la communauté archéologique.

4.4 APPORT PERSONNEL

Cette étude a été une expérience enrichissante et transformative pour moi, tant sur le plan académique que personnel. Au départ, j'avais très peu de connaissances dans le domaine de l'archéologie, mais ce mémoire m'a permis d'explorer ce domaine fascinant et d'en apprendre davantage sur l'importance des séries temporelles dans l'analyse des données archéologiques. Cette immersion m'a ouvert les yeux sur la complexité et la richesse des informations que l'on peut extraire des données anciennes, renforçant ainsi ma passion pour la recherche interdisciplinaire.

J'ai également eu la chance de participer à un article de publication scientifique dont je suis co-auteur avec mon directeur de recherche Kévin Bouchard et ma co-directrice de recherche Ségolène Vandeveld. Cette opportunité m'a permis de travailler en étroite collaboration avec des chercheurs expérimentés, d'affiner mes compétences en rédaction académique et de comprendre les exigences d'un article scientifique. Ce processus m'a non seulement enrichi sur le plan intellectuel, mais a également renforcé ma confiance en moi en tant que chercheur.

En outre, cette étude m'a permis d'acquérir de nouvelles compétences en matière de traitement et d'analyse de données, notamment à travers l'application de techniques avancées comme le Dynamic Time Warping et les modèles d'apprentissage automatique. Ces compétences seront précieuses pour mes projets futurs et m'ont préparé à relever de nouveaux défis dans le domaine de la recherche.

Enfin, l'expérience de ce mémoire m'a appris l'importance de la curiosité intellectuelle et de la persévérance dans la recherche. Chaque obstacle surmonté m'a rapproché de la compréhension des dynamiques archéologiques et a renforcé mon engagement à poursuivre mes études dans ce domaine.

BIBLIOGRAPHIE

Aach, J. and G. M. Church (2001). "Aligning gene expression time series with time warping algorithms." Bioinformatics **17**(6): 495-508.

Bagnall, A., et al. (2017). "The great time series classification bake off: a review and experimental evaluation of recent algorithmic advances." Data mining and knowledge discovery **31**: 606-660.

Ben Taieb, S., et al. (2012). "A review and comparison of strategies for multi-step ahead time series forecasting based on the NN5 forecasting competition." Expert Systems with Applications **39**(8): 7067-7083.

Bianchette, T. A., et al. (2023). "Machine learning based anomaly detection for sedimentological data: Application to a Holocene multi-proxy paleoenvironmental reconstruction from Laguna Boquita, Jalisco, Mexico." Marine Geology **464**.

Bishop, C. (2006). Pattern Recognition and Machine Learning. **16**: 140-155.

Brockwell, P. J. and R. A. Davis (2016). Introduction to time series and forecasting, Springer.

Chalapathy, R. and S. Chawla (2019). "Deep learning for anomaly detection: A survey." arXiv preprint arXiv:1901.03407.

Chatfield, C. (2016). The Analysis of Time Series: An Introduction, Sixth Edition, CRC Press.

Chawla, N. V., et al. (2002). "SMOTE: synthetic minority over-sampling technique." Journal of artificial intelligence research **16**: 321-357.

Chen, K.-C. (2022). "Introduction to Artificial Intelligence and Robotics." Artificial Intelligence in Wireless Robotics: 1-24.

Cook, D. J., et al. (2013). "CASAS: A Smart Home in a Box." Computer (Long Beach Calif) **46**(7).

Dama, F. and C. Sinoquet (2021). Time Series Analysis and Modeling to Forecast: a Survey.

Dau, - H. A., et al. (2019). "- The UCR Time Series Archive." - IEEE/CAA Journal of Automatica Sinica - **6**(- 6): - 1293.

Doshi-Velez, F. and B. Kim (2017). "Towards a rigorous science of interpretable machine learning." arXiv preprint arXiv:1702.08608.

Ermshaus, A., et al. (2023). Window Size Selection in Unsupervised Time Series Analytics: A Review and Benchmark. Advanced Analytics and Learning on Temporal Data, Cham, Springer International Publishing.

Fawcett, T. and F. Provost (2013). Data Science for Business.

Galeazzi, F., et al. (2016). "Web-based visualization for 3D data in archaeology: The ADS 3D viewer." Journal of Archaeological Science: Reports **9**: 1-11.

Gardner, E. S. (2006). "Exponential smoothing: The state of the art—Part II." International Journal of Forecasting **22**(4): 637-666.

- Gera, U. K. (2022). "Smart farming." Advances in Computational Intelligence and Robotics: 211-221.
- Gil, A., et al. (2021). "Towards Smart Data Selection From Time Series Using Statistical Methods." IEEE Access **9**: 44390-44401.
- Guo, Y., et al. (2023). "Application of Support Vector Machine Algorithm Incorporating Slime Mould Algorithm Strategy in Ancient Glass Classification." Applied Sciences **13**: 3718.
- Hastie, T., et al. (2009). The Elements of Statistical Learning: Data Mining, Inference, and Prediction, Second Edition (Springer Series in Statistics).
- Hyndman, R. J. and G. Athanasopoulos (2021). Forecasting: Principles and Practice, OTexts.
- Jeong, Y.-S., et al. (2011). "Weighted dynamic time warping for time series classification." Pattern Recognit. **44**: 2231-2240.
- Jordan, M. I. and T. M. Mitchell (2015). "Machine learning: Trends, perspectives, and prospects." Science **349**(6245): 255-260.
- Keogh, E., et al. (2004). SEGMENTING TIME SERIES: A SURVEY AND NOVEL APPROACH. Data Mining in Time Series Databases: 1-21.
- Keogh, E. J. and M. J. Pazzani (2001). Derivative Dynamic Time Warping. Proceedings of the 2001 SIAM International Conference on Data Mining (SDM): 1-11.
- Långkvist, M., et al. (2014). "A Review of Unsupervised Feature Learning and Deep Learning for Time-Series Modeling." Pattern Recognition Letters **42**.
- LeCun, Y., et al. (2015). "Deep learning." Nature **521**(7553): 436-444.
- Leierer, L., et al. (2019). "Insights into the timing, intensity and natural setting of Neanderthal occupation from the geoarchaeological study of combustion structures: A micromorphological and biomarker investigation of El Salt, unit Xb, Alcoy, Spain." PLOS ONE **14**(4): e0214955.
- Li, S., et al. (2020). "Slime mould algorithm: A new method for stochastic optimization." Future Generation Computer Systems: 300-323.
- Linchamps, P., et al. (2023). "Bioclimatic inference based on mammal community using machine learning regression models: perspectives for paleoecological studies." Frontiers in Ecology and Evolution **11**.
- Malhotra, P., et al. (2016). "LSTM-based encoder-decoder for multi-sensor anomaly detection." arXiv preprint arXiv:1607.00148.
- Malhotra, P., et al. (2015). Long Short Term Memory Networks for Anomaly Detection in Time Series.
- Medina-Alcaide, M. Á. (2020). Lighting the darkness of the caves with Paleolithic Art: an integral and interdisciplinary vision of the Internal Archaeological Context and the wood charcoals Iluminando la oscuridad de las cuevas con manifestaciones gráficas paleolíticas: una visión integral e interdisciplinar del Contexto Arqueológico Interno y de los carbones de madera.
- Medina-Alcaide, M. Á., et al. (2023). "35,000 years of recurrent visits inside Nerja cave (Andalusia, Spain) based on charcoals and soot micro-layers analyses." Scientific Reports **13**(1): 5901.
- Mitchell, T. M. (1997). Machine learning, McGraw-hill New York.

- Nagra, G., et al. (2017). "Dating stalagmites in mediterranean climates using annual trace element cycles." Scientific Reports **7**(1): 621.
- Oonk, S. and J. Spijker (2015). "A supervised machine-learning approach towards geochemical predictive modelling in archaeology." Journal of Archaeological Science **59**: 80-88.
- Orengo, H. A., et al. (2020). "Automated detection of archaeological mounds using machine-learning classification of multisensor and multitemporal satellite data." Proceedings of the National Academy of Sciences **117**(31): 18240-18250.
- Orengo, H. A. and A. Garcia-Molsosa (2019). "A brave new world for archaeological survey: Automated machine learning-based potsherd detection using high-resolution drone imagery." Journal of Archaeological Science **112**: 105013.
- Pérez, J., et al. (2019). "On the turing completeness of modern neural network architectures." arXiv preprint arXiv:1901.03429.
- Petitjean, F., et al. (2016). "Faster and more accurate classification of time series by exploiting a novel dynamic time warping averaging algorithm." Knowledge and Information Systems **47**.
- Quigley, B., et al. (2018). "A Comparative Analysis of Windowing Approaches in Dense Sensing Environments." Proceedings **2**(19): 1245.
- Russell, S. J. (2010). Artificial intelligence : a modern approach, Third edition. Upper Saddle River, N.J. : Prentice Hall.
- Sakoe, H. and S. Chiba (1978). "Dynamic programming algorithm optimization for spoken word recognition." IEEE Transactions on Acoustics, Speech, and Signal Processing **26**(1): 43-49.
- Salvador, S. and P. Chan (2007). "Toward accurate dynamic time warping in linear time and space." Intell. Data Anal. **11**(5): 561–580.
- Shumway, R. and D. Stoffer (2017). Time Series Analysis and Its Applications With R Examples.
- Siarni-Namini, S., et al. (2018). A Comparison of ARIMA and LSTM in Forecasting Time Series. 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA).
- Singh, M., et al. (2023). Machine Learning and AI based Robotic System for Archaeological Research. 2023 International Conference on Inventive Computation Technologies (ICICT).
- Sutton, R. S. and A. G. Barto (2018). Reinforcement learning: An introduction, 2nd ed. Cambridge, MA, US, The MIT Press.
- Tsinaslanidis, P. and D. Kugiumtzis (2014). "A prediction scheme using perceptually important points and dynamic time warping." Expert Systems with Applications **41**: 6848–6860.
- Vandevælde, S. (2019). There is no soot without fire ! : micro-chronological study of fuliginous concretions. Case study : the Grotte of Mandrin (France) Université Panthéon-Sorbonne - Paris I.
- Vandevælde, S. (2024: 566). "Precision dating pinpointing time between use of ancient fireplaces." Nature.
- Vandevælde, S., et al. (2017). "Establishment of occupation chronicles in Grotte Mandrin using sooted concretions: Rethinking the Middle to Upper Paleolithic transition." Journal of Human Evolution **112**: 70-78.

- Vandevælde, S., et al. (2019). "Archaeological layer, archaeological floor and parietal soot films: a micro-chronological approach to understanding occupations in caves
Couche archéologique, sol archéologique et films de suie pariétaux : une approche micro-chronologique de l'occupation des cavités." Archéologie, société et environnement **19**(1): 1-15.
- Vandevælde, S., et al. (2020). "Sooty concretions in archaeological contexts: what informative potential?
Des concrétions fuligineuses en contextes archéologiques : quel potentiel informatif ?" Géomorphologie : relief, processus, environnement **26**(4): 241-254.
- Vandevælde, S., et al. (2021). "Identification of parietal carbonates' annual precipitation rate for a microchronological setting of pyrogenic archaeological occupations: the Grotte Mandrin (Malataverne, Drôme, France) case." Bulletin de la Société Géologique de France **192**: 9.
- Vaswani, A., et al. (2017). Attention is All you Need. Neural Information Processing Systems.
- Wang, Y., et al. (2023). "Archaeological Predictive Modeling Using Machine Learning and Statistical Methods for Japan and China." ISPRS International Journal of Geo-Information **12**(6): 238.
- Wang, Z., et al. (2022). "An adaptive sliding window for anomaly detection of time series in wireless sensor networks." Wireless Networks **28**(1): 393-411.
- Wilson, D. L. (1972). "Asymptotic Properties of Nearest Neighbor Rules Using Edited Data." IEEE Transactions on Systems, Man, and Cybernetics **SMC-2**(3): 408-421.
- Winters, P. R. (1960). "Forecasting Sales by Exponentially Weighted Moving Averages." Management Science **6**(3): 324-342.
- Wu, N., et al. (2020). "Deep transformer models for time series forecasting: The influenza prevalence case." arXiv preprint arXiv:2001.08317.
- Zhao, J. and L. Itti (2016). "shapeDTW: Shape Dynamic Time Warping." Pattern Recognition **74**: 171-184.