

Détection d'anomalies de comportement de barrage

Noémie Roussel^{2,1}, Guillaume Veylon¹, Claudio Carvajal¹, Capucine Masson², Frédéric Andrian²

¹ RECOVER, INRAE, Aix-Marseille Université

² Artelia Group

RESUME

L'évaluation de la sécurité des barrages nécessite le suivi et l'analyse de données d'auscultation (déplacements, sous-pressions), récoltées tout au long de la vie de l'ouvrage. Les méthodes statistiques couramment utilisées aujourd'hui telles que la méthode HST et ses dérivées présentent de nombreuses limites. Elles ne permettent pas la prise en compte des couplages entre les variables mesurées, et supposent à l'avance la forme des équations modélisant le comportement hydromécanique de l'ouvrage. Les méthodes d'apprentissage automatiques basées sur les données (machine-learning) sont susceptibles de dépasser ces limites.

Dans la présente étude, deux approches d'apprentissage automatique sont testées sur des données réelles de déplacements d'un barrage poids. Une première approche de régression (à l'aide de l'algorithme d'Arbres de Régressions Boostés par Histogramme) est mise en œuvre pour analyser le comportement du barrage. Un changement de comportement mécanique dans les déplacements radiaux d'un pendule est identifié par l'observation de l'effet du temps et par déviance de la prédiction par rapport aux déplacements observés. Une seconde approche d'apprentissage semi-supervisé (méthode de détection de nouveauté) est utilisée sur les déplacements radiaux et tangentiels des deux pendules. Elle met en évidence une apparition de mesures anormales, cohérente avec le changement de comportement observé par méthode de régression. Il est ainsi montré que ces méthodes peuvent ensemble constituer un outil d'aide à l'analyse des données d'auscultation et permettent de détecter des changements de comportement du barrage et l'apparition d'anomalies. Ainsi, des potentielles pathologies peuvent être détectées, et des mesures correctives adaptées et efficaces peuvent être prises dans les meilleurs délais.

Mots-clefs Barrage, auscultation, machine-learning, détection d'anomalies

I. INTRODUCTION

La surveillance du comportement des barrages est essentielle tout au long de la vie des ouvrages. Elle passe par l'analyse des données d'auscultation, qui correspondent à l'ensemble des données de déplacements, de sous-pressions, de débits de fuites, ou tout autres variables caractéristiques de son comportement. Ce comportement dépend de variables extérieures, que sont les variations saisonnières, la température, la cote de la retenue, ou encore les précipitations.

Les méthodes traditionnelles d'analyse des données d'auscultation sont les méthodes statistiques HST et ses dérivées (HST-T, HST-P) (De Granrut, 2019; Mata et al., 2014; Salazar et al., 2017, 2016). Leur objectif est de modéliser le comportement du barrage en le décomposant en une partie réversible liée aux variations saisonnières et hydrostatiques, et une partie irréversible. Cette dernière peut être l'indice d'une pathologie ou d'une anomalie dans le comportement du barrage. Ces méthodes présentent cependant certaines limites. La forme des équations de comportement est postulée *a priori*, les variables d'entrée sont supposées être indépendantes et les effets de seuil et de retard ne sont pas bien pris en compte.

Les méthodes d'apprentissage basées sur les données (machine-learning) peuvent permettre de dépasser ces limites, car elles se basent uniquement sur les données d'apprentissage, sans *a priori* sur la forme de la réponse de la variable prédite. Cette branche de l'intelligence artificielle repose sur la capacité d'un ordinateur à apprendre à partir de données et à améliorer ses performances au fil des itérations. Elles sont de plus en plus utilisées dans de nombreux domaines d'ingénierie comme dans le domaine de la surveillance de l'état des structures (SHM), car elles permettent d'analyser effacement des quantités de données de plus en plus importantes. Elles restent peu utilisées dans l'auscultation des barrages, bien qu'elles aient déjà fait preuve de leur efficacité (Alocén et al., 2022; De Granrut et al., 2019; Hellgren et al., 2021; Mata, 2011; Mojtaba et al., 2022; Salazar et al., 2022, 2015; Simon, 2022; Tayfur et al., 2005).

Ces outils sont principalement utilisés dans le cadre de l'apprentissage supervisé en régression. L'objectif est de construire un modèle prédictif du comportement du barrage reliant des variables d'entrée (variable explicative, ou prédicteur) et une variable de sortie (cible), dans le but d'analyser l'influence des variables explicatives sur le comportement du barrage. Le modèle obtenu permet également de détecter une dérive ou une anomalie si le comportement observé s'écarte significativement et durablement du comportement prédit. Différents modèles plus ou moins complexes peuvent être utilisés. Selon Salazar, les réseaux de neurones et les arbres de régression boostés se sont avérés être les algorithmes les plus efficaces (Salazar et al., 2017, 2015). Ils ont été testés par plusieurs auteurs (Mata, 2011; Salazar et al., 2016; Tayfur et al., 2005) et ont démontré des performances prometteuses. Salazar a également proposé un modèle basé sur la classification pour détecter une classe normale parmi plusieurs classes anormales (Salazar et al., 2021). Cette technique d'apprentissage supervisé nécessite que chaque ensemble de variables explicatives soit accompagné d'une valeur cible connue, permettant ainsi au modèle d'apprendre à faire des prédictions. De tel jeux de données sont compliqué à obtenir, car il est souvent compliqué de connaître avec certitude la nature normale ou anormale des données. Une solution peut être de les générer à partir d'un modèle numérique par éléments finis (FEM). Cependant, les données simulées numériquement sont souvent moins complexes que la réalité. L'apprentissage non supervisé permet de s'affranchir du problème de labélisation des données, ce qui constitue un avantage par rapport aux méthodes supervisées. Ce sont ces deux approches qui sont appliquées dans le cadre de cette étude sur les données réelles d'auscultation d'un grand barrage poids.

II. Présentation du cas d'étude

Le barrage étudié est un barrage poids en béton d’une hauteur de 31 m au-dessus de sa fondation, avec un volume de réservoir de 24 Mm³. La crête du barrage mesure 150 m de long. Les pentes des faces amont et aval sont respectivement de 1V/0,125H et 1V/0,85H. Construit il y a presque un siècle, le système de surveillance n’a été installé que depuis les années 1980.

Le comportement hydrostatique du barrage est surveillé via des piézomètres et des points de mesure de débits de fuite. Son comportement mécanique est suivi à l’aide de deux pendules inversés mesurant les déplacements radiaux et tangentiels à proximité de sa section transversale la plus élevée. Le pendule PL1 mesure le déplacement entre le sommet du barrage et le sommet de la fondation, tandis que le pendule PL2 mesure les déplacements entre le sommet du barrage et un point situé à environ 15 m en dessous de l’interface barrage-fondation (FIGURE 1).




FIGURE 1. Vue plan et en coupe du barrage

La base de données est composée d’environ 2 300 mesures pour chaque instrument. Contrairement à la plupart des barrages, sa face amont est asséchée pendant plusieurs mois de l’année, ce qui influence la sous-pression, les déplacements et les débits de fuite, conférant ainsi un comportement particulier à l’ouvrage.

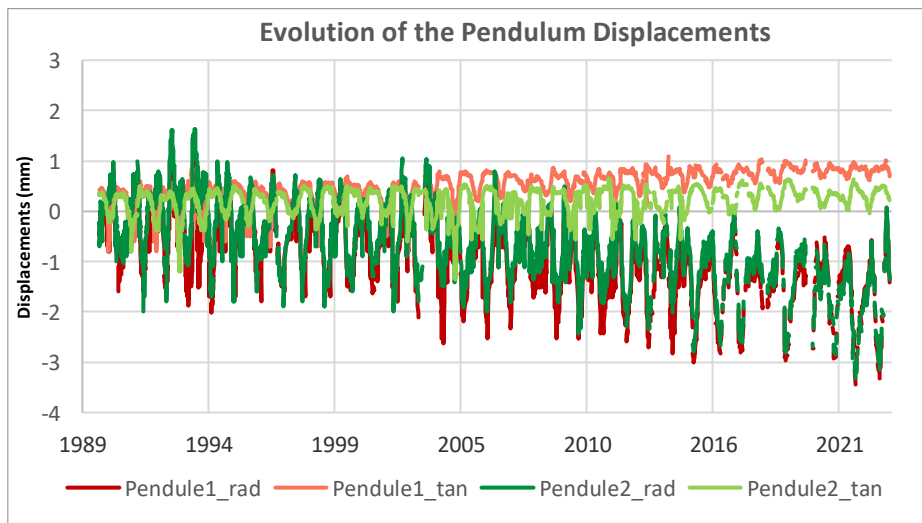


FIGURE 2. Données brutes disponibles des pendules

III. Méthodes

Cet article se concentre sur l'analyse des mesures des déplacements du pendule 1 ("Pendule1"). En examinant ses enregistrements (

FIGURE 2), de nombreuses variations sont observées, et notamment une certaine dérive qui pourraient témoigner d'une anomalie de comportement. Des analyses préliminaires ont montré que les méthodes statistiques classiques telles que HST ne permettent pas de détecter correctement la dérive anormale observée.

Deux approches sont testées pour analyser les données d'auscultation et tenter d'identifier l'anomalie :

1. La méthode de régression qui a pour but de modéliser les données de déplacements, à l'aide de l'algorithme *Histogram Gradient Boosting Regression Trees* (HGBRT) et
2. Une méthode d'apprentissage semi-supervisé pour la détection d'anomalies basé sur la détection de nouveauté avec le Local Outlier Factor (LOF).

La bibliothèque Python Scikit-learn (Pedregosa et al., 2011) est utilisée pour l'apprentissage, développée par l'INRIA.

A. détection d'anomalie par apprentissage supervisé (régression)

En apprentissage supervisé, l'entraînement se base sur des données labellisées. Chaque point de données d'entrée est associé à une sortie correspondante. Une régression est réalisée sur le déplacement enregistré par le pendule, qui caractérise le comportement du barrage. Plusieurs variables externes sont utilisées pour prédire ce déplacement, et donné comme paramètres d'entrée au modèle. On les appelle « variables explicatives », et sont de trois types : temporel, hydrostatique et thermique, comme présentés en FIGURE 3. .

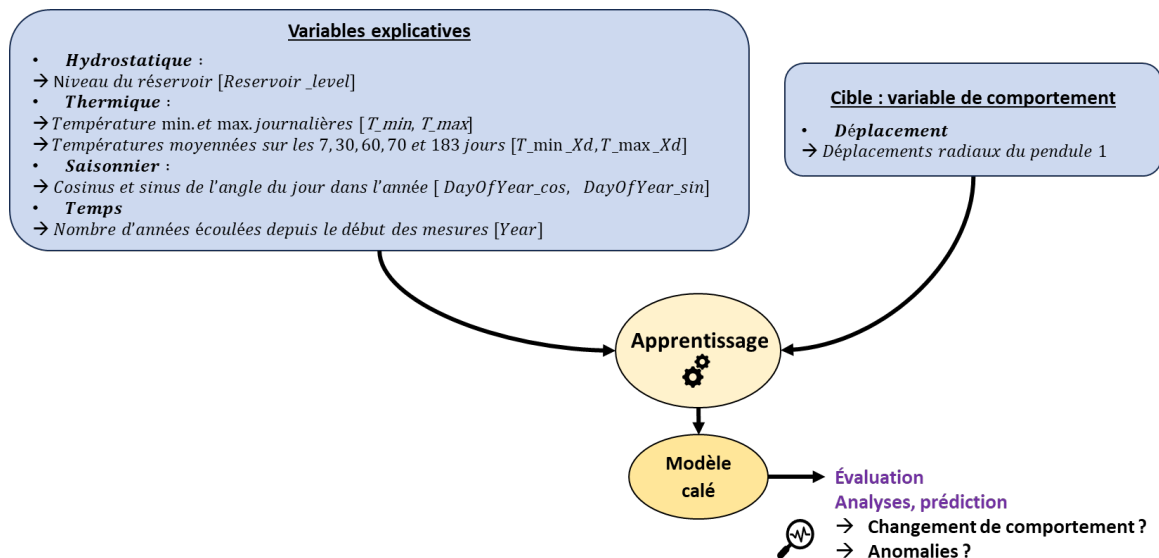


FIGURE 3. Principe d'apprentissage et données d'entrées

Divers algorithmes de régression ont été testés, tels que les Réseaux de Neurones, les modèles d'ensemble basés sur les Arbres de Décision, tels que le *Bagging* (Forêts Aléatoires ou *Random Forest*) et le *Boosting*. Il a été observé que la plupart des méthodes offraient des performances similaires, mais l'algorithme des Arbres de Régressions Boostées par Histogramme ou *Histogram Boosted Regression Trees* (HBRT) s'est avéré être le meilleur algorithme au regard de sa rapidité et du fait qu'il gère la présence de valeurs manquantes dans les données des variables explicatives. Le Boosting entraîne un modèle simple (dans ce cas un arbre de décision) de manière séquentielle, chaque nouveau modèle étant entraîné pour corriger les erreurs faites par les précédents, en utilisant la fonction de descente de gradient. Le HBRT est une variante du *Boosting* qui accélère l'entraînement en regroupant les données de chaque variable explicative en groupes à la manière d'un histogramme pour construire les arbres de décision. Les résultats suivants ont été obtenus en utilisant cet algorithme.

Apprentissage sur l'ensemble des données et analyse de l'effet du temps

La partie gauche de la FIGURE 4 détaille la méthodologie employée pour la détection d'anomalie. Dans un premier temps, le modèle est calé sur l'ensemble des données pour observer l'influence des variables explicatives sur le déplacement, et en particulier l'influence du temps. Afin de réduire les risques de sur-apprentissage, les données sont divisées une première fois aléatoirement en un ensemble d'entraînement (80%), et un ensemble de données test (20 %). Ces proportions sont typiquement utilisées en machine-learning (Salazar et al., 2015) et permettent dans notre cas d'avoir un nombre assez large de données de test. Les données de test ne sont pas vues par le modèle dans le cadre de l'apprentissage, et serviront à évaluer la capacité de généralisation du modèle. Ce processus est réalisé une première fois avec une liste exhaustive de variables explicatives, parmi lesquels seuls les plus significatifs sont conservés. Un second entraînement est ensuite réalisé avec les variables explicatives choisis, afin d'obtenir le modèle final.

L'importance explicative des variables explicatives est évaluée par la méthode de permutation. Les données de la variable à évaluer sont mélangées aléatoirement afin de rompre leurs corrélations avec la cible et les autres variables explicatives. Un modèle est entraîné et testé sur ces données. Plus le score du modèle diminue en raison de cette permutation, plus la variable en question est considérée comme étant importante pour le modèle.

Une fois l'entraînement réalisé avec les meilleures variables explicatives, sa qualité et sa performance sont évalués de différentes façons. D'une part, deux métriques sont utilisées pour caractériser les performances du modèle. La racine carrée de l'erreur quadratique moyenne (*Root Mean Squared Error*, RMSE) représente l'écart-type des résidus, exprimé dans la même unité que les données initiales. Elle permet d'évaluer l'ampleur moyenne des erreurs de prédiction, une valeur plus faible indiquant une meilleure performance. Le coefficient de détermination (R^2) mesure la proportion de variance expliquée par le modèle entre les valeurs prédites et les valeurs cibles réellement observées. Un R^2 égal à 1 indique que la cible est parfaitement prédite par le modèle, tandis qu'une valeur proche de zéro reflète une incapacité à expliquer la variabilité de la cible. D'autre part, le modèle est évalué au regard de son sens physique. Il est étudié au travers de l'influence des variables explicatives sur la variable de comportement. Enfin, le choix du modèle dépend aussi de sa flexibilité et sa facilité d'utilisation, ou encore du temps de calcul nécessaire à son entraînement.

Si le modèle a un score satisfaisant et que l'influence des variables extérieures sur la variable de comportement présente une interprétation physique logique, le modèle peut être considéré comme satisfaisant. L'influence de la variable « temps » est ainsi révélatrice de potentielles dérives ou anomalies de comportement, car elle constitue la partie irréversible du comportement observé.

Apprentissage sur une première partie des données et comparaison à la prédiction

Une autre méthode permettant d'identifier un changement de comportement consiste à caler le modèle sur une première période de temps (en divisant les données en un sous ensemble d'entraînement et de test comme vu précédemment), et d'ensuite prédire le comportement futur sur des données d'évaluation. Cette méthode est résumée en [FIGURE 4](#). Si le modèle calé sur la première période est satisfaisant, un écart entre la prédiction et les valeurs réelles des données à évaluer peut-être révélateur d'un changement de comportement. C'est le cas si les données d'évaluation restent dans le même domaine que les données d'entraînement.

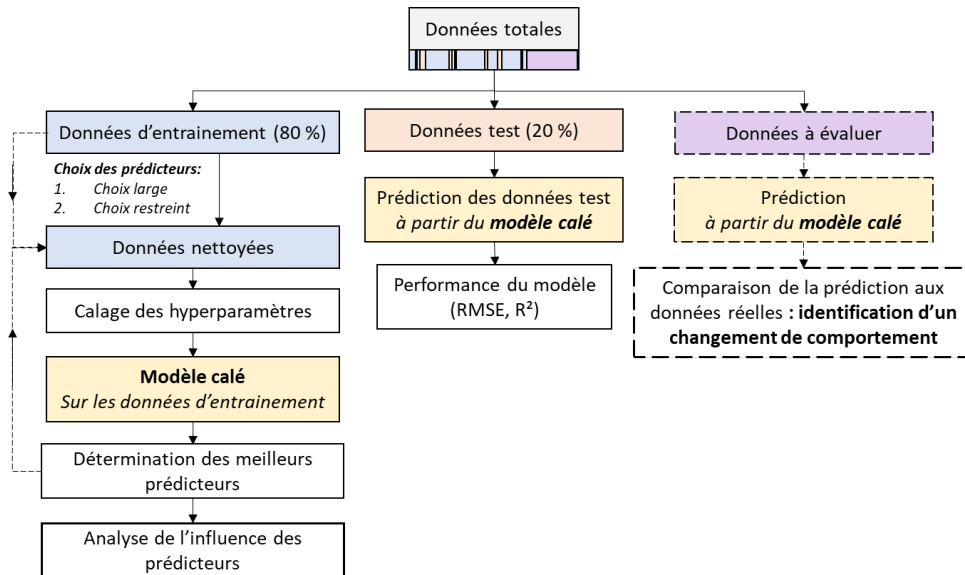


FIGURE 4. Méthodologie de régression pour la détection d'anomalies

B. détection d'anomalie par apprentissage semi-supervisé

En apprentissage non supervisé, le modèle est entraîné sur des données dites non labellisées. Aucune métrique n'est donc disponible pour évaluer directement le modèle. Sa fiabilité est testée en croisant ses résultats avec d'autres méthodes, comme la régression mentionnée précédemment.

Dans cette étude, la méthode de détection de nouveauté est utilisée avec l'algorithme du *Local Outlier Factor* (LOF). Le modèle est entraîné sur un premier ensemble de données, correspondant au comportement initial, considéré comme « normal », du barrage. Les valeurs suivantes sont ensuite introduites dans le modèle, qui évalue leur degré d'anomalie à l'aide d'un score appelé LOF. Pour cela, il compare la densité locale de chaque nouvelle valeur à celles des données initiales, en utilisant la distance aux k plus proches voisins. Si la densité locale d'une valeur est significativement plus faible que celle de ses voisins, elle est considérée comme une anomalie. Cette approche permet de détecter un changement de comportement du barrage par rapport à son fonctionnement normal appris sur les données d'entraînement.

La localisation des points de données par rapport à leurs voisins peut être visualisée en deux dimensions grâce à une Analyse en Composantes Principales (ACP). Pour obtenir plus d'informations sur la nature de l'anomalie, l'histogramme des scores est tracé, ainsi que son évolution dans le temps.

Le nombre de voisins à considérer dans le calcul de la densité locale est ajusté de manière empirique en observant la forme de la fonction de décision autour des points d'entraînement. Il a été fixé à 50 dans la présente étude. Le score LOF minimal pour qu'un point soit considéré comme anormal est typiquement pris à 1,5 (Scikit-learn developers, n.d.).

Les quatre mesures des pendules sont utilisées comme données d'entrée. Ces mesures correspondent aux déplacements radiaux et tangentiels des pendules 1 et 2.

IV. Résultats

A. détection d'anomalie par apprentissage supervisé (regression)

Le premier calage du modèle sur l'ensemble des données permet de calculer l'importance de chaque variable explicative (FIGURE 5).

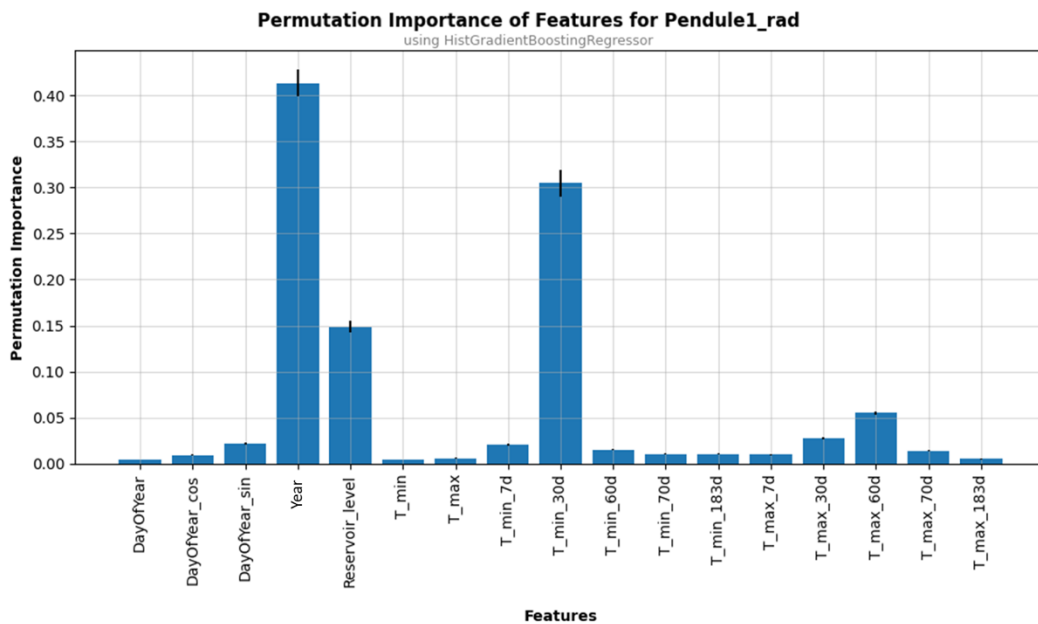


FIGURE 5. Importance des variables explicatives du modèle calé sur l'ensemble des données (période 1984-2016) par la méthode de permutation

La meilleure variable explicative de chaque catégorie est retenue : le sinus de l'angle annuel (DayOfYear_sin) pour la composante saisonnière, la variable de temps (Year), la cote de la retenue (Reservoir_level), la température minimale et la température maximale moyennées sur 30 et 60 jours respectivement (T_min_30d, T_max_60d) pour les températures.

Le modèle final est donc calé en considérant ces variables explicatives uniquement. Les scores obtenus sur les données de test sont les suivants : RMSE = 0.22 mm, $R^2 = 0.89$. Compte tenu de l'amplitude des données qui est de 4.2 mm, la précision du modèle nous semble suffisante.

L'influence des variables explicatives est observée sur les graphiques de dépendance partielles (FIGURE 6). La variable saisonnière a une faible influence sur le déplacement, contrairement aux variables de températures. Plus elles sont élevées, plus le déplacement vers l'amont (négatif) a une amplitude élevée. Cela correspond à l'effet de dilatation thermique du béton qui opère lorsque la température augmente. L'influence du niveau du réservoir montre un déplacement vers l'aval lorsque celui-ci augmente au-delà d'une valeur seuil d'environ 1980 mNGF. Enfin, l'influence de l'année reflète une lente dérive temporelle moyenne de l'ordre de 0.1 mm / 5 ans qui semble s'accélérer à la suite d'un saut la 20^e année (en 2004).

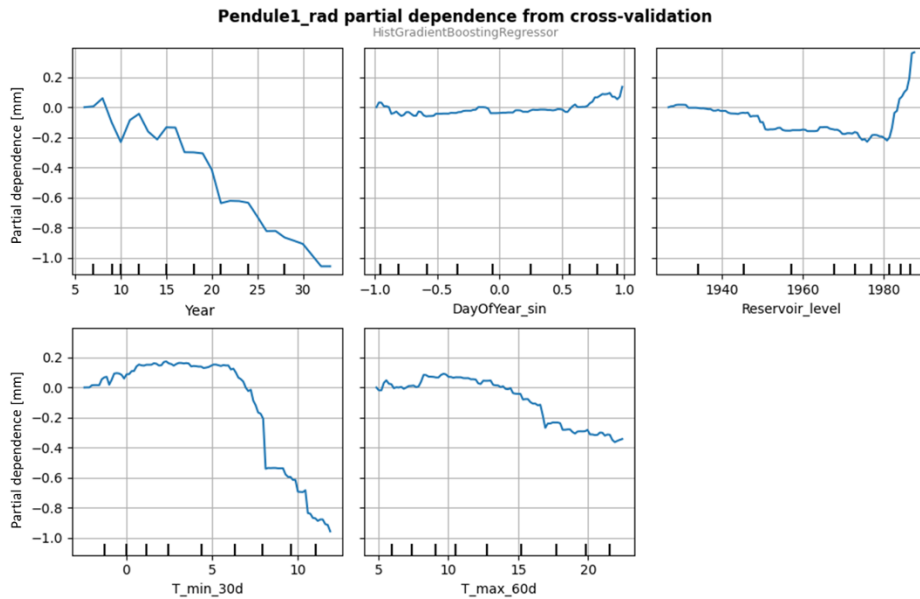


FIGURE 6. Graphiques de dépendances partielles : influence des variables explicatives sur le déplacement enregistré par le pendule

Afin de confirmer la dérive temporelle observée, l'apprentissage est ensuite réalisé uniquement sur les données entre 1989 et 2000, et la prédiction sur les données suivantes (FIGURE 7). Lors de la phase d'apprentissage, la performance est évaluée par validation croisée. Un R^2 de 0.83 ± 0.03 et un RMSE de 0.26 ± 0.02 mm est obtenu. Les données évaluées restant dans le même cadre que les données d'apprentissage (températures, côte de retenue similaires), elles devraient pouvoir être expliquées par le modèle avec cette même précision. Si un écart est observé par rapport à la prédiction, c'est qu'il n'est plus capable d'expliquer les déplacements observés ; il y a donc eu changement de comportement.

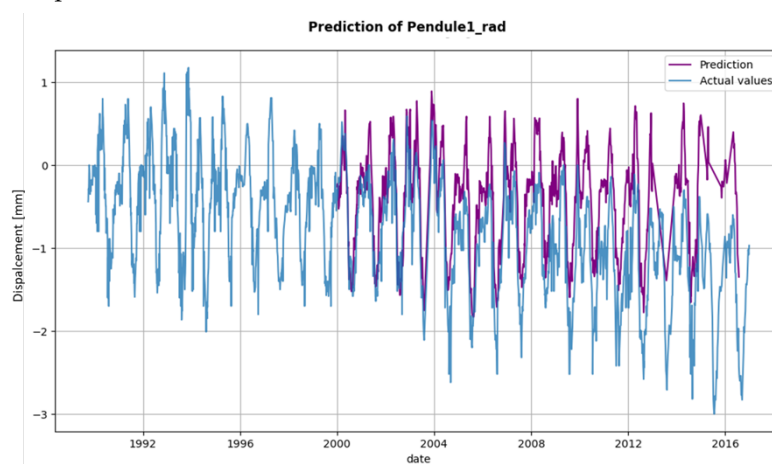


FIGURE 7. Prédiction du déplacement enregistré par le pendule entre 2000 et 2016, et données réelles

La prédiction est correcte jusqu'à 2004, date à partir de laquelle elle semble s'éloigner progressivement des données réelles, avec un écart de plus d'un millimètre. Afin de mieux visualiser cet écart et définir un seuil d'anomalie, le graphique de la prédiction en fonction des valeurs réelles est tracé (FIGURE 8). Une prédiction parfaite serait donc située sur la droite $y=x$. Les points bleus correspondent à une prédiction réalisée sur les données d'entraînement. Le nuage de points est délimité visuellement par une frontière correspondant à 3 fois l'erreur moyenne absolue de la prédiction sur les données d'entraînement. Les points en dehors de cette délimitation sont considérés comme étant anormaux car trop éloigné de la prédiction. Le second nuage de points correspond à la prédiction sur les données d'évaluation (après 2000), et sont colorés en fonction de la valeur du paramètre Year. Cela permet de confirmer visuellement que le nuage de points s'éloigne progressivement hors de la frontière tracée avec le temps, en particulier à partir de 2004.

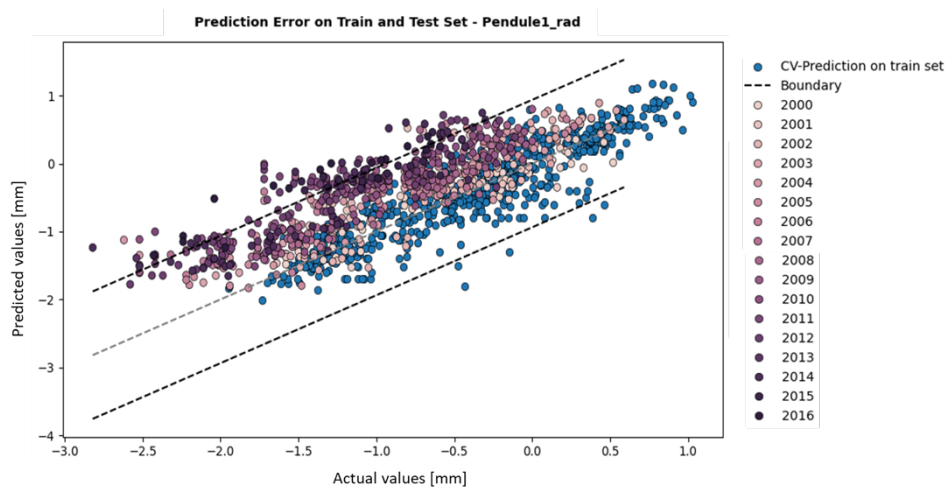


FIGURE 8. Données prédites en fonction des données réelles – sur l'ensemble d'entraînement (en bleu) et d'évaluation (en violet)

B. détection d'anomalie par apprentissage semi-supervisé

La méthode d'apprentissage semi-supervisé est mise en œuvre sur les données de déplacement des deux pendules. L'entraînement est réalisé sur les données de 1984 à 1999, correspondant à la période du comportement initial, et les données suivantes (1999 – 2024) sont évaluées. La FIGURE 9 présente le résultat de cette évaluation : en rouge pour les données anormales (*outliers*), et en violet pour les données normales (*inliers*). On constate que les données anormales deviennent majoritaires à partir de 2004.




FIGURE 9. Résultats de la détection d'anomalie par facteur local d'anomalie en détection de nouveauté

Pour visualiser la séparation entre les points normaux et les anomalies, les quatre variables d'entrées sont projetées sur deux composantes principales à l'aide d'une Analyse en Composantes Principales (ACP). La fonction de frontière de décision est représentée sur la [FIGURE 10](#). Les *inliers* se situent à proximité des données d'entraînement, tandis que les *outliers* forment un groupe qui s'éloigne des données initiales.

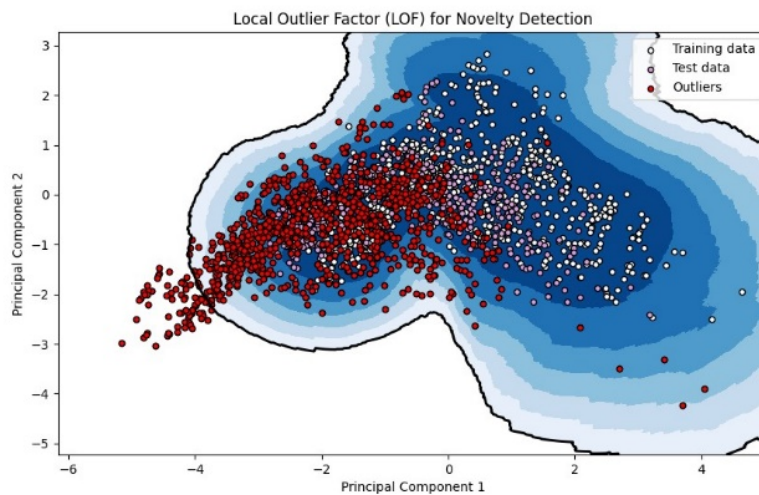


FIGURE 10. Visualisation par ACP de la fonction de frontière de décision

L'histogramme des scores d'anomalies (LOF) est tracé ([FIGURE 11](#)), la ligne pointillée rouge séparant les valeurs normales des valeurs anormales. L'évolution des scores au fil du temps est également tracée sur la [FIGURE 11](#), avec le seuil d'anomalie tracé en rouge.

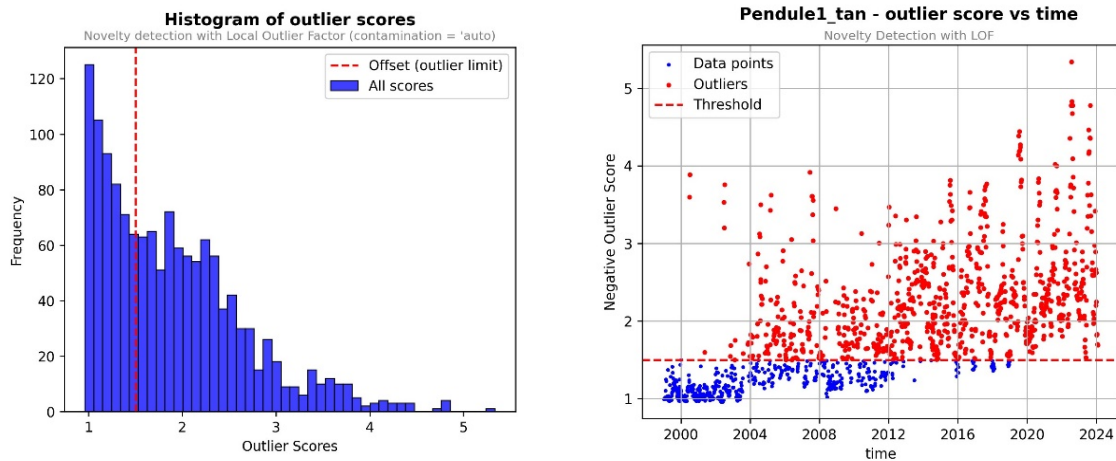


FIGURE 11. Histogramme des scores d'anomalies (à gauche) et leur évolution dans le temps (à droite)

Les deux figures montrent une répartition relativement homogène des scores d'anomalies. L'évolution temporelle de ces scores montre un premier saut en janvier 2004 avec l'apparition de nombreux points identifiés comme anormaux. D'autres sauts et baisses semblent s'être produits en 2008, 2013, 2016, 2020 et 2023, dont les deux premiers se retrouvent sur les graphiques de dépendance partielle (FIGURE 6) obtenus par régression.

V. Discussions

L'arbre de régression boosté par histogramme (HBRT), qui montre de hautes performances pour un temps de calcul faible, permet de prédire les déplacements radiaux du pendule 1. Les paramètres de HBRT sont facilement configurables avec une recherche par grille ou aléatoire, ce qui le rend très facile à utiliser. De plus, cet algorithme gère les données manquantes parmi les variables explicatives. Cela permet de réaliser des prédictions sur des points où peut manquer une donnée de variable extérieure, chose fréquente en auscultation.

En réalisant une régression sur l'ensemble des données, nous avons analysé l'influence des variables extérieures sur le déplacement, et en particulier l'influence du temps, ici par année. Cela a permis de révéler une dérive irréversible progressive des déplacements, qui s'accélère en 2004. L'autre méthode consistant à caler la régression sur un premier jeu de données « normales » et prédire la réponse du barrage à partir des variables extérieures suivantes a permis de mettre en évidence un écart de prédiction se creusant à partir de 2004. Le modèle n'étant plus capable d'expliquer la variabilité des déplacements de l'ouvrage, on peut considérer qu'il y a eu un changement de comportement avec l'apparition d'une anomalie.

La méthode de détection de nouveauté permet de confirmer cette hypothèse. Ce changement de comportement est observé en considérant comme données évaluées les déplacements tangentiels et radiaux des deux pendules simultanément. Cette méthode permet de détecter l'apparition d'un comportement anormal lorsqu'une succession de mesures anormales se suivent dans le temps. L'histogramme des scores des points aberrants est également un outil utile qui permet de voir si

les points s'écartent progressivement de la norme, ou si certains points sont fortement isolés du reste. Il donne un aperçu de la nature des anomalies, que ce soient des changements progressifs ou soudains.

REFERENCES

- Alocén, P., Fernández-Centeno, M.Á., Toledo, M.Á., 2022. PREDICTION OF DAM BEHAVIOUR BASED ON MACHINE LEARNING METHODS. Presented at the 16th International Benchmark Workshop on Numerical Analysis of Dams, Ljubljana.
- De Granrut, M., 2019. Analyse et interprétation de la pression d'eau en fondation des barrages-voûtes à partir des mesures d'auscultation (These de doctorat). Université Grenoble Alpes (ComUE).
- De Granrut, M., Simon, A., Dias, D., 2019. Artificial neural networks for the interpretation of piezometric levels at the rock-concrete interface of arch dams. *Engineering Structures* 178, 616–634. <https://doi.org/10.1016/j.engstruct.2018.10.033>
- Hellgren, R., Malm, R., Ansell, A., 2021. Performance of data-based models for early detection of damage in concrete dams. *Structure and Infrastructure Engineering* 17, 275–289. <https://doi.org/10.1080/15732479.2020.1737146>
- Mata, J., 2011. Interpretation of concrete dam behaviour with artificial neural network and multiple linear regression models. *Engineering Structures - ENG STRUCT* 33, 903–910. <https://doi.org/10.1016/j.engstruct.2010.12.011>
- Mata, J., Castro, A., Costa, J., 2014. Constructing statistical models for arch dam deformation. *Structural Control and Health Monitoring* 21. <https://doi.org/10.1002/stc.1575>
- Mojtaba, F., Moradabbasi, M., Ahangar Kolaei, S.H., 2022. HYDROSTATIC MACHINE LEARNING MODEL FOR PREDICTION OF CONCRETE DAM BEHAVIOUR. Presented at the 16th International Benchmark Workshop on Numerical Analysis of Dams, Ljubljana.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., 2011. Scikit-learn: Machine Learning in Python. *MACHINE LEARNING IN PYTHON*.
- Salazar, F., Conde, A., Irazábal González, J., Vicente, D.J., 2021. Anomaly Detection in Dam Behaviour with Machine Learning Classification Models. *Water* 13, 2387. <https://doi.org/10.3390/w13172387>
- Salazar, F., Irazábal, J., Vicente, D.J., 2022. PREDICTION AND INTERPRETATION OF DAM RESPONSE WITH BOOSTED REGRESSION TREES. Presented at the 16th International Benchmark Workshop on Numerical Analysis of Dams, Ljubljana.
- Salazar, F., Moya, R.M., Toledo, M.Á., Oñate, E., 2017. Data-Based Models for the Prediction of Dam Behaviour: A Review and Some Methodological Considerations. *Archives of Comp. Meths. Engng.* <https://doi.org/10.1007/s11831-015-9157-9>
- Salazar, F., Toledo, M.A., Oñate, E., Morán, R., 2015. An empirical comparison of machine learning techniques for dam behaviour modelling. *Structural Safety* 56, 9–17. <https://doi.org/10.1016/j.strusafe.2015.05.001>
- Salazar, F., Toledo, M.Á., Oñate, E., Suárez, B., 2016. Interpretation of dam deformation and leakage with boosted regression trees. *Engineering Structures* 119, 230–251. <https://doi.org/10.1016/j.engstruct.2016.04.012>

- Scikit-learn developers, n.d. 2.7. Novelty and Outlier Detection [WWW Document]. scikit-learn. URL https://scikit-learn/stable/modules/outlier_detection.html (accessed 7.1.24).
- Simon, A., 2022. BEHAVIOR PREDICTION OF A CONCRETE ARCH DAM: DATA-BASED MODELS USED BY THE FORMULATOR OF THE THEME A IN AN INDUSTRIAL CONTEXT. Presented at the 16th International Benchmark Workshop on Numerical Analysis of Dams, Ljubljana.
- Tayfur, G., Swiatek, D., Wita, A., Singh, V., 2005. Case Study: Finite Element Method and Artificial Neural Network Models for Flow through Jeziorsko Earthfill Dam in Poland. *Journal of Hydraulic Engineering-asce - J HYDRAUL ENG-ASCE* 131. [https://doi.org/10.1061/\(ASCE\)0733-9429\(2005\)131:6\(431\)](https://doi.org/10.1061/(ASCE)0733-9429(2005)131:6(431))