

# Conception des blocs de terre comprimée guidée par les réseaux Bayésiens

Sarah NASSAR<sup>1</sup>, Jacqueline SALIBA<sup>1</sup>, Cédric BAUDRIT<sup>1</sup>, Nadia SAIYOURI<sup>1</sup>

<sup>1</sup> Université de Bordeaux, UMR 5295, Institut de Mécanique et d'Ingénierie (I2M), CNRS, Esplanade des Arts et Métiers, 33405 Talence, France

**RÉSUMÉ** En vue de la transition écologique, construire en terre semble une option intéressante d'un point de vue environnemental. Les blocs de terre comprimée (BTC) sont faciles à mettre en œuvre et assurent un confort hygrothermique. Néanmoins, les propriétés de la terre sont assez variables et il n'y a pas de formulation unique pour tous les types de terre. La norme XP13-901 relative aux BTC recommande un fuseau granulaire pour des résultats favorables notamment en termes de résistance mécanique. Par contre, la bonne performance des BTC n'est pas garantie si tous les paramètres qui entrent en jeu ne sont optimisés comme le pourcentage d'argile, la quantité d'eau, le mode de cure, la pression de compactage ainsi que le type et le pourcentage de stabilisant. Afin d'optimiser la formulation, plusieurs essais de laboratoire sont requis ce qui peut être coûteux en termes de prix, de temps et de matière. Dans cet article, un réseau bayésien est proposé en se basant sur des données issues de la littérature. Le modèle a la capacité de prédire les performances des BTC, notamment la résistance à la compression, en fonction de diverses formulations et différents procédés de fabrication. Le modèle peut également être utilisé comme un outil d'aide à la fabrication des BTC pour atteindre les performances ciblées.

**Mots-clés** bloc de terre comprimée, prédiction, réseau bayésien, résistance à la compression

## I. INTRODUCTION

Les blocs de terre comprimée (BTC) gagnent de plus en plus d'intérêt grâce aux avantages qu'ils présentent. En effet, ils sont à base de terre et ne sont pas cuits ce qui les rend à faible impact environnemental et simplifie aussi leur recyclage en fin de vie. Morton et al (2005) ont démontré une réduction de 14 tonnes de CO<sub>2</sub> en utilisant une maçonnerie en BTC au lieu de blocs de béton dans une maison de 97 m<sup>2</sup>. De plus, ce type de maçonnerie assure une régulation de l'humidité et un confort thermique permettant une économie d'énergie. A noter que les BTC absorbent dix fois plus d'humidité que les briques de terre cuite (Pacheco-Torgal and Jalali, 2012). Toutefois, étant à base de terre, il n'existe pas une composition unique pour les BTC mais plutôt des recommandations de fabrication. En effet, le sol présente une grande variabilité et des essais de laboratoire sont nécessaires à chaque fois pour optimiser la composition, les conditions de conservation et de fabrication des BTC (Fardoun et al., 2022a, 2022b; Kouta et al., 2021). Ces essais consomment beaucoup de matière, de temps et d'argent. Il est ainsi important de comprendre les relations entre les différents paramètres de fabrication qui rentrent en jeu et les propriétés recherchées. Vu la complexité et la grande variabilité des données sur les BTC dans la littérature, les méthodes issues de l'intelligence artificielle telles que l'apprentissage de modèles guidé par les

données offrent des perspectives pertinentes pour concevoir des outils de recommandations. Ces approches ont été utilisées pour concevoir des outils d'aide à la décision dans différents domaines dont celui du génie civil et de la construction (Lu et al., 2012). Mohtasham Moein et al (2022) ont réalisé une revue bibliographique des différents modèles utilisés dans la littérature pour la prédiction de la performance mécanique du béton en montrant l'importance de l'adaptation du choix du modèle à la complexité du problème posé. Tran et Do (2021) ont prédit l'indice portant californien pour des sols stabilisés en se basant sur le modèle de Light GBM qui dépend du calcul d'arbres de décision. Tran (2021) a utilisé les réseaux de neurones pour prédire la résistance à la compression de sédiments stabilisés. Même si ces approches ont prouvé leurs potentiels prédictifs, ils requièrent une quantité de données substantielles et les modèles sont difficilement interprétables et compris par des experts ce qui engendre un manque de confiance. Ils peuvent être regroupés dans une classe de modèles qui sont considérés comme des « boîtes noires ». Parmi les choix de modèles d'apprentissages possibles, celui des réseaux Bayésiens (Finn V. Jensen , Thomas D. Nielsen, 2007) présente l'avantage de décrire des systèmes complexes entachés d'incertitude, d'être lisible et interprétable par des non avertis et la capacité d'intégrer des connaissances expertes dans le processus d'apprentissage. Ils permettent de transformer la connaissance contenue dans des données parfois imprécises en modèle interprétable tout en intégrant une représentation flexible du savoir. Ils sont capables de porter un jugement ou d'apporter une estimation même lorsque les données ne sont pas toutes observées. Cette approche a été étudiée et utilisée dans des domaines qui vont du biomédical à la pétro-physique (Wiegerinck et al., 2011). Uitdehaag et al (2022) ont utilisé des réseaux bayésiens pour évaluer des sols dans des enquêtes judiciaires. Les réseaux bayésiens ont été aussi adoptés par Hu (2021) pour la prédiction de la liquéfaction de sols graveleux et par Taalab et al (2015) pour prédire le type de sol et tracer des cartographies.

L'objectif du présent travail est de construire un réseau bayésien pour exploiter les paramètres de fabrication des BTC à base des sédiments du bassin d'Arcachon et la résistance à la compression correspondante. Ces sédiments ont montré une très grande variabilité en fonction de la zone de prélèvement (Nassar et al., 2023) et ce modèle va permettre (1) de proposer une configuration vraisemblable des paramètres pour obtenir les performances mécaniques ciblées et (2) de prédire la résistance à la compression en fonction des paramètres observés.

## II. RÉSEAUX BAYÉSIENS

Les réseaux bayésiens sont des modèles graphiques probabilistes dont les nœuds représentent des variables aléatoires et dont les arcs codent les dépendances conditionnelles entre les variables. Ils permettent de représenter un modèle factorisé d'une loi de probabilité jointe qui peut s'écrire comme le produit de la distribution de probabilité de chaque nœud et de ses parents. Si l'ensemble des nœuds parents d'un nœud  $X_i$  est désigné par  $\text{Pa}(X_i)$ , la probabilité jointe peut se réécrire :

$$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | \text{Pa}(X_i)) \quad (1)$$

où  $P(X_i | \text{Pa}(X_i))$  représente la probabilité conditionnelle associée à la variable  $X_i$  sachant  $\text{Pa}(X_i)$ .

La construction d'un réseau Bayésien peut être établie par apprentissage à partir d'une base de données  $D$ . Celle-ci consiste à trouver un réseau Bayésien  $B \in B_n$  à l'aide d'un algorithme de recherche heuristique qui maximise une fonction score  $\phi(B,D)$  établie à partir de l'équation (1) utilisant la base de données  $D$ . Différentes techniques d'apprentissage permettent d'identifier soit la structure du graphe (i.e. la topologie), soit les paramètres du réseau (i.e. les distributions de probabilités conditionnelles) ou une combinaison des deux à partir de données substantielles et/ou incomplètes combinées à une élicitation par des experts (Heckerman, 2008). A noter que le travail de l'expert n'est pas évident et a une tendance à être subjectif dans certains cas. Pour cela, des travaux antérieurs sur ce sujet ont proposé des outils sur lesquels l'expert peut s'appuyer. L'outil le plus simple à utiliser est l'échelle de probabilité (Druzdzel and Gaag, 2000). Cette dernière sert à attribuer des probabilités aux appréciations que l'expert peut avoir. L'utilisation de ces réseaux consiste en une "requête" exprimée sous forme de probabilités conditionnelles. La tâche la plus courante consiste à estimer les probabilités marginales  $P(X_Q|X_E)$  où  $X_Q$  est un ensemble de variables de requête et  $X_E$  un ensemble de variables observées. L'inférence consiste alors à calculer la probabilité de chaque état d'une variable  $X_Q$  lorsque l'état pris par les autres variables  $X_E$  est connu (Salmerón et al., 2018).

### III. BASE DE DONNÉES & CONSTRUCTION DU MODÈLE

Les BTC sont un mélange de terre, d'eau et dans certains cas de stabilisants compactés dans un moule. Entre autres propriétés, la performance mécanique et plus particulièrement la résistance à la compression sèche à 28 jours est recherchée. Cette résistance est affectée non seulement par la constitution des BTC mais aussi par le processus de fabrication et les conditions de conservation. La norme XP P13-901 (2001) donne des recommandations sur la granulométrie et la plasticité de la terre pour obtenir des résultats satisfaisants. La quantité optimale d'eau est souvent déterminée par des essais Proctor (afnor, 2014). Par ailleurs, l'augmentation de la pression de compactage et de la quantité de stabilisant peuvent améliorer la résistance (Mkaouar et al., 2019; Morel et al., 2007; Taallah et al., 2014). La relation entre ces paramètres est complexe et il est difficile de prédire l'impact final sur la résistance à la compression. Pour cela, des résultats d'expérimentation issus de la littérature ont été collectés pour constituer une base de données afin d'en extraire de la connaissance à l'aide des réseaux bayésiens. En particulier, l'intérêt est porté sur les conditions de fabrication et leur impact sur la résistance à la compression ( $R_c$ ) des BTC. Les paramètres retenus comportent les propriétés de la terre, du mélange et de la fabrication i.e. les pourcentages de sable, de limon et d'argile contenus dans la terre, l'indice de plasticité ( $I_p$ ) et la limite de liquidité ( $W_l$ ) de la fraction fine, la teneur en eau du mélange, le type et pourcentage de stabilisant et la pression de compactage. Les liants hydrauliques les plus couramment utilisés et en particulier le ciment et la chaux ont été considérés dans cette étude. D'autres paramètres comme la teneur en matière organique, la valeur de bleu sols ou la densité ayant un impact sur la performance peuvent être aussi ajoutés en plus de l'effet d'autres types d'additions et de liants. Par contre, ces derniers n'ont pas été pris en compte dans cette étude à cause de la limitation des données. La base de données collectée comporte au total 276 données.

Structure du réseau bayésien

Les variables identifiées ont été discrétisées en intervalles pertinents et représentatifs à l'aide de l'expertise. Par exemple, le pourcentage de ciment, variant entre 0 et 20%, a été divisé en cinq intervalles ( $[0 ; 1[$  pour les BTC non stabilisés et  $[1 ; 5[$ ,  $[5 ; 10[$ ,  $[10 ; 15[$  et  $[15 ; 20]$ ) permettant de suivre au plus précis l'évolution de l'impact de l'addition du ciment.

Les modèles ont été construits et implémentés en utilisant la bibliothèque python pyAgrum<sup>1</sup> (Gonzales et al., 2017) dédiée aux modèles graphiques probabilistes permettant aux modélisateurs de créer, gérer et effectuer des inférences avec les réseaux Bayésiens. La construction de la première structure (figure 1 (a)) s'est basée sur l'algorithme Greedy Hill Climbing (méthode similaire à la méthode de descente de gradient adaptée aux données discrètes qui part d'un graphe non connecté, et manipule des arcs jusqu'à un minimum local) avec le score BDeu (Bayesian Dirichlet Equivalent) (Carvalho, 2009).

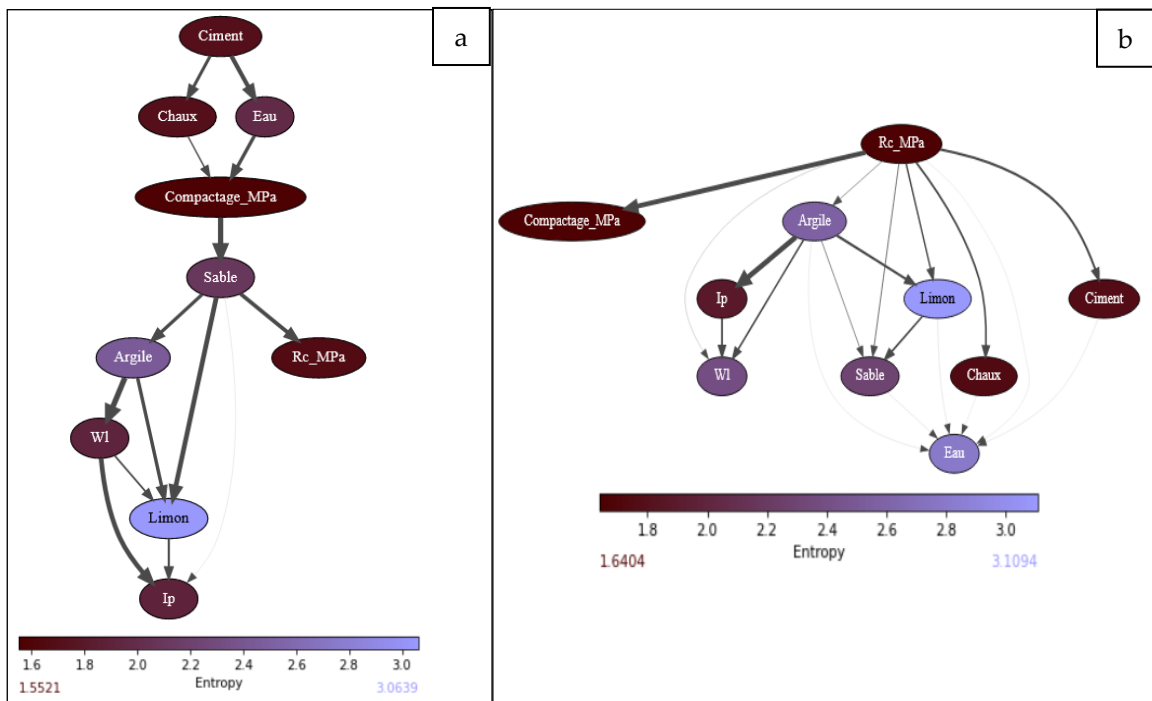


FIGURE 1. Structures basées sur : a) un score et de b) l'expertise

Le modèle a bien appris par exemple que les trois constituants du sol (le sable, le limon et l'argile) étaient bien reliés et ceci s'explique par leur complémentarité. Le modèle considère par exemple la chaux comme un des nœuds enfants du ciment ce qui peut être dû à la présence d'une combinaison de stabilisants dans la base de données. En revanche, la structure du modèle appris révèle des relations de dépendances discutables. En effet, le modèle suggère, par exemple, que la résistance à la compression est indépendante du pourcentage de ciment, de chaux et de la quantité d'eau dès l'instant que le pourcentage de sable est connu (i.e. seule la connaissance sur le pourcentage de sable est suffisante pour évaluer la résistance à la compression). Or, la connaissance du pourcentage du sable n'est pas suffisante à elle seule pour prédire la

<sup>1</sup> <https://agrum.gitlab.io/>

performance mécanique d'où l'importance de l'intégration de la connaissance experte pour enrichir les relations entre les paramètres. De ce fait, une seconde structure de modèle (voir Fig. 1.b) a été apprise en intégrant des connaissances expertes dans le processus d'apprentissage.

Des contraintes ont été ainsi imposées lors de l'apprentissage des données entre la résistance et tous les composants du mélange ainsi que la pression de compactage ayant un impact direct sur la performance (Mostafa and Uddin, 2016; Taallah et al., 2014) (figure 1 (b)). Le ciment et la chaux sont en relation avec l'eau pour prendre en compte la quantité d'eau consommée par les réactions d'hydratation. La quantité d'eau dépend aussi du mélange sable, limon et argile pour assurer une certaine plasticité et une densité optimale du mélange. Par ailleurs, l'argile dicte la limite de liquidité et l'indice de plasticité qui, à leur tour, sont corrélés à travers la limite de plasticité. A savoir que la limite de liquidité est une caractéristique du type d'argile et aura aussi un impact direct sur la résistance du BTC.

#### Validation

Il est important de valider le modèle afin de vérifier la précision des prédictions. Avec une petite base de données, comportant moins de 1000 combinaisons de BTC, un surapprentissage risque d'apparaître, c'est-à-dire que le modèle peut être adapté aux données d'entraînement mais pas à de nouvelles données (Brownlee, 2020). Pour cela, les données sont séparées en deux ensembles dédiés respectivement à l'apprentissage et à la validation. Il s'agira d'une validation croisée « tous sauf un » (Arlot, 2017). Elle consiste à exclure une seule donnée à la fois de la base de données pour tester la prédiction de sa résistance à la compression en fonction de ses autres paramètres.

**TABLEAU 1. Matrice de confusion de la structure basée sur l'expertise**

		Valeur prédite de la résistance à la compression (MPa)				
		[0 ;2[	[2 ;4[	[4 ;6[	[6 ;8]	
		Occurrence	155	71	46	4
Valeur réelle de la résistance à la compression (MPa)	[0 ;2[	146	<b>129</b>	13	4	0
	[2 ;4[	70	23	<b>34</b>	12	1
	[4 ;6[	49	3	22	<b>21</b>	3
	[6 ;8]	11	0	2	9	<b>0</b>

Le modèle est évalué à l'aide d'une matrice de confusion établie entre les valeurs réelles et les valeurs prédites. Le tableau 1 montre la matrice de confusion de la structure basée sur de l'expertise. Cette matrice confronte les valeurs prédites de la résistance aux valeurs réelles. Par exemple, parmi 155 données prédites en étant dans l'intervalle [0 ;2[, 129 ont été correctement prédites et les autres 23 appartiennent à l'intervalle [2 ; 4[ et 3 à l'intervalle [4 ; 6[. Le modèle est alors précis à 83% pour la prédiction des résistances inférieures à 2 MPa. Selon cette matrice, c'est l'intervalle pour lequel le modèle est le plus fiable. Le manque de précision peut être dû à la non prise en compte de certains paramètres comme la teneur en matière organique, les conditions de cure, le type de compactage, la taille et la forme des éprouvettes ainsi que les conditions de

réalisation des essais mécaniques. Une plus grande base de données permettrait aussi des prédictions plus pertinentes.

Un calcul de précision donne une estimation globale de l'exactitude des probabilités du réseau. Il s'agit du rapport entre le nombre de prédictions correctes au niveau de la diagonale de la matrice (184) et le nombre total de prédictions (276). Le tableau 2 résume les précisions de chacune des deux structures évoquées dans cet article.

**TABLEAU 2. Précision des structures**

Structure	Précision
Basée sur un score - Figure 1 (a)	60%
Basée sur l'expertise pure - Figure 1 (b)	67%

La structure s'appuyant sur l'intégration de l'expertise présente une meilleure précision que le modèle issu purement des données (voir Tableau 2). Les résultats montrent l'importance de la contribution de l'expert et l'avantage que présente les réseaux bayésiens par rapport à d'autres modèles. Toutefois, des freins existent dans ce type d'approche. En effet, l'expertise présente aussi des incertitudes et ne pourra pas optimiser toutes les relations ou combler toutes les valeurs manquantes sur certains intervalles et ceci limitera la précision (Taalab et al., 2015). D'autres structures combinant l'expertise et le score pourront être aussi testées.

#### IV. RÉSULTATS ET DISCUSSION

Pour l'exploitation du modèle dans la conception de BTC, la structure couplant expertise et données (Figure 1 (b)) présentant une plus grande précision est retenue. Une première utilisation du modèle est d'estimer la résistance à la compression du BTC formé à base des sédiments prélevés du même endroit. Ces derniers ont été caractérisés par des essais géotechniques et les propriétés suivantes sont obtenus : Argile (47%), Limon (31%), Sable (22%), WI (62%), Ip (38%). Un exemple d'inférence est montré dans la Figure 2. Il s'agit d'un BTC non stabilisé formé à base des sédiments dont les propriétés connues ont été fixées avec  $8\% \leq E_{eau} < 12\%$  et une pression de compactage considérée entre 1 et 2 MPa. Dans ce cas, le modèle estime que la résistance à la compression sèche à 28 jours pour le BTC sera vraisemblablement située entre 0 et 2 MPa avec une probabilité de 76,5% ce qui n'est pas suffisant pour être utilisé en construction (Jiménez Delgado and Guerrero, 2007). Ce modèle permettra alors d'anticiper et de proposer des alternatives pour optimiser les conditions de fabrication. Par exemple, l'utilisateur peut modifier certains paramètres comme la quantité d'eau, le pourcentage de ciment, etc. L'ajout de stabilisant peut être une solution d'amélioration de la performance mécanique et peut à son tour être testée sur le modèle avant tout essai de laboratoire. La figure 3 montre un exemple d'optimisation du cas dressé dans la figure 2. Il s'agit toujours des mêmes sédiments mais qui ont été cette fois-ci stabilisés par un mélange de ciment (entre 5 et 10%). La quantité d'eau est incrémentée pour prendre en compte l'hydratation du ciment et la stabilisation physique par compactage est proposée dans l'intervalle de [4 ; 8 MPa [ . Dans ce cas, la résistance à la compression prévue est bien améliorée et pourra atteindre 4 à 6 MPa. Le mélange des sédiments des différentes régions

du bassin d’Arcachon ayant des distributions granulaires différentes pourrait être aussi envisagé pour l’optimisation du mélange en se basant sur ce réseau.

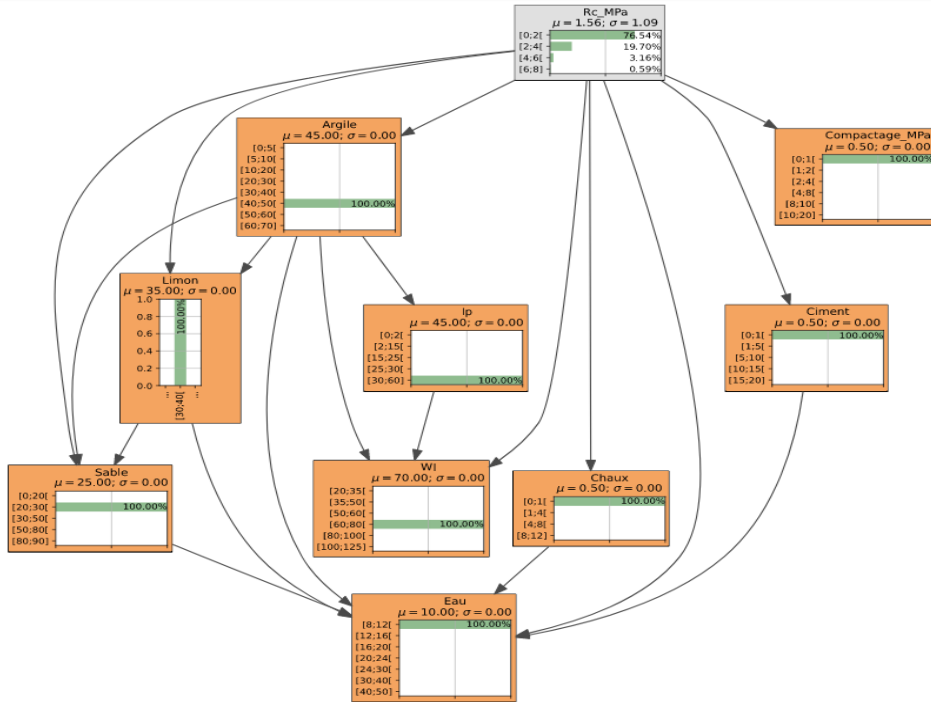


FIGURE 2. Exemple d’inférence de la structure basée sur de l’expertise pour un BTC non stabilisé

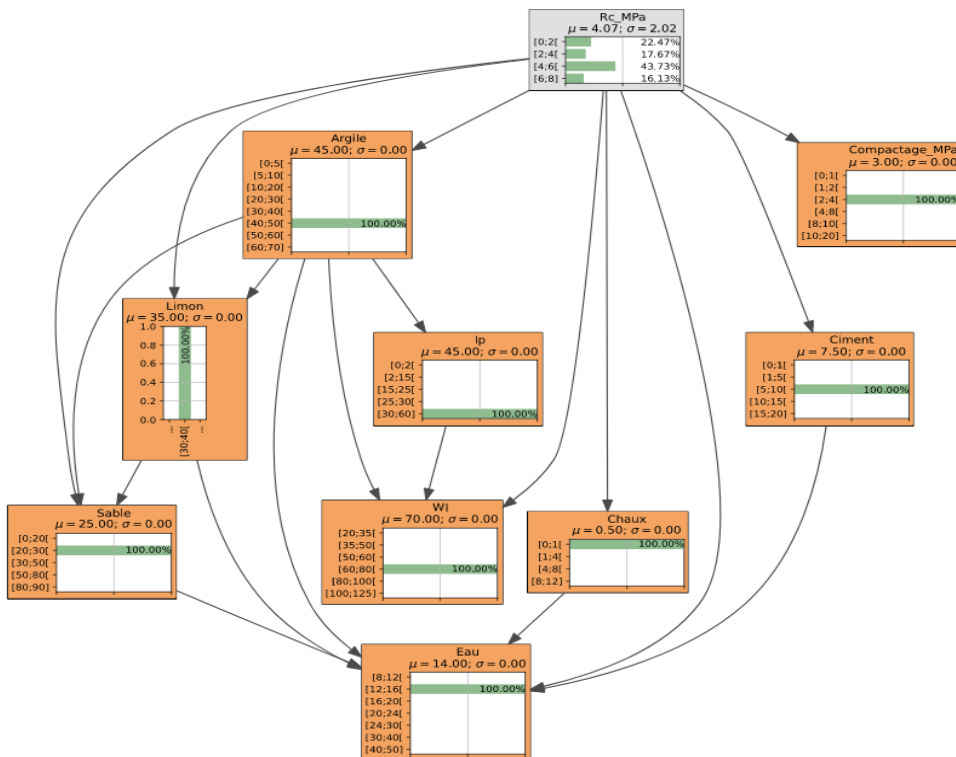


FIGURE 3. Exemple d’inférence de la structure basée sur de l’expertise pour un BTC stabilisé

En addition, pour un mélange bien adapté, le réseau bayésien permet aussi de cibler les propriétés voulues. Dans ce cas, il s'agit du chemin inverse et la résistance à la compression peut être fixée sur un intervalle donné afin d'observer les tendances des autres paramètres. Ceux qui seront difficiles à modifier peuvent aussi être fixés. Des stabilisations physiques ou chimiques proposées par le modèle pourront être pris en compte si c'est possible. Ainsi, les degrés de liberté seront restreints l'un après l'autre selon les choix adoptés pour enfin concevoir une combinaison de paramètres conduisant au résultat espéré.

## V. CONCLUSIONS ET PERSPECTIVES

Les paramètres de fabrication des BTC sont nombreux avec des relations complexes et ont un impact sur leurs performances mécaniques. Par ailleurs, la variabilité des propriétés des terres nécessite une optimisation du mélange afin d'assurer une certaine consistance au niveau des performances visées. Cet article propose un modèle de conception de BTC à base de sédiments guidé par des réseaux bayésiens. Contrairement aux autres modèles d'apprentissage automatique, les réseaux bayésiens sont facilement interprétables et permettent d'intégrer de l'expertise. Dans le travail présenté, une meilleure précision a été obtenue pour le modèle s'appuyant sur l'expertise pour la définition des relations entre les paramètres. En s'appuyant sur ce modèle, la valorisation de sédiments dans des BTC est alors guidée avec une précision de 67% pour la prédiction de la résistance à la compression avant réalisation d'essais mécaniques au laboratoire.

Une plus grande base de données aidera sans doute à de meilleures prédictions et à élargir les intervalles de l'étude. Les paramètres considérés dans ce modèle pourront être affinés par la suite pour couvrir de plus grandes possibilités de fabrication de BTC comme une stabilisation par d'autres liants chimiques ou par ajout de fibres. Il serait aussi intéressant d'examiner d'autres propriétés comme les propriétés hygrothermiques et les indicateurs de la durabilité. Des méthodes d'apprentissage automatique différentes comme les réseaux de neurones, seront aussi investigués pour servir de comparaison.

## RÉFÉRENCES

- afnor, 2014. NF P94-093 Sols : Reconnaissance et essais — Détermination des références de compactage d'un matériau — Essai Proctor Normal — Essai Proctor modifié [WWW Document]. URL <https://viewerbdc.afnor.org/pdf/viewer/LGm05JFnXHA1?proxy=true> (accessed 1.24.23).
- Arlot, S., 2017. Validation croisée 37.
- Brownlee, J., 2020. LOOCV for Evaluating Machine Learning Algorithms. MachineLearningMastery.com. URL <https://machinelearningmastery.com/loocv-for-evaluating-machine-learning-algorithms/>
- Carvalho, A.M., 2009. Scoring functions for learning Bayesian networks. Inesc-Id Tec Rep 12, 1–48.
- Druzdzal, M.J., Gaag, L.C. van der, 2000. Building probabilistic networks: "Where do the numbers come from?" ; guest editors"; introduction. IEEE Trans. Knowl. Data Eng. 12, 481.
- Fardoun, H., Saliba, J., Coureau, J.-L., Cointe, A., Saiyouri, N., 2022a. Long-Term Deformations and Mechanical Properties of Fine Recycled Aggregate Earth Concrete. Appl. Sci. 12, 11489. <https://doi.org/10.3390/app122211489>
- Fardoun, H., Saliba, J., Saiyouri, N., 2022b. Evolution of acoustic emission activity throughout fine recycled aggregate earth concrete under compressive tests. Theor. Appl. Fract. Mech. 119, 103365. <https://doi.org/10.1016/j.tafmec.2022.103365>

- Finn V. Jensen , Thomas D. Nielsen, 2007. Bayesian Networks and Decision Graphs.
- Gonzales, C., Torti, L., Wuillemin, P.-H., 2017. aGrUM: a Graphical Universal Model framework. Presented at the IEA/AIE 2017 - 30th International Conference on Industrial Engineering and Other Applications of Applied Intelligent Systems, Springer, p. 171. [https://doi.org/10.1007/978-3-319-60045-1\\_20](https://doi.org/10.1007/978-3-319-60045-1_20)
- Heckerman, D., 2008. A Tutorial on Learning with Bayesian Networks, in: Holmes, D.E., Jain, L.C. (Eds.), *Innovations in Bayesian Networks: Theory and Applications*, Studies in Computational Intelligence. Springer, Berlin, Heidelberg, pp. 33–82. [https://doi.org/10.1007/978-3-540-85066-3\\_3](https://doi.org/10.1007/978-3-540-85066-3_3)
- Hu, J., 2021. A new approach for constructing two Bayesian network models for predicting the liquefaction of gravelly soil. *Comput. Geotech.* 137, 104304. <https://doi.org/10.1016/j.compgeo.2021.104304>
- Jiménez Delgado, M.C., Guerrero, I.C., 2007. The selection of soils for unstabilised earth building: A normative review. *Constr. Build. Mater.* 21, 237–251. <https://doi.org/10.1016/j.conbuildmat.2005.08.006>
- Kouta, N., Saliba, J., Saiyouri, N., 2021. Monitoring of earth concrete damage evolution during drying. *Constr. Build. Mater.* 313, 125340. <https://doi.org/10.1016/j.conbuildmat.2021.125340>
- Lu, P., Chen, S., Zheng, Y., 2012. Artificial Intelligence in Civil Engineering. *Math. Probl. Eng.* 2012, e145974. <https://doi.org/10.1155/2012/145974>
- Mkaouar, S., Maherzi, W., Pizette, P., Zaitan, H., Benzina, M., 2019. A comparative study of natural Tunisian clay types in the formulation of compacted earth blocks. *J. Afr. Earth Sci.* 160, 103620. <https://doi.org/10.1016/j.jafrearsci.2019.103620>
- Mohtasham Moein, M., Saradar, A., Rahmati, K., Ghasemzadeh Mousavinejad, S.H., Bristow, J., Aramali, V., Karakouzian, M., 2022. Predictive models for concrete properties using machine learning and deep learning approaches: A review. *J. Build. Eng.* 63, 105444. <https://doi.org/10.1016/j.jobe.2022.105444>
- Morel, J.-C., Pkla, A., Walker, P., 2007. Compressive strength testing of compressed earth blocks. *Constr. Build. Mater.* 21, 303–309. <https://doi.org/10.1016/j.conbuildmat.2005.08.021>
- Morton, T., Stevenson, F., Taylor, B., Smith, N.C., 2005. Low Cost Earth Brick Construction: 2 Kirk Park, Dalguise - Monitoring and Evaluation [WWW Document]. URL <https://www.abebooks.com/9780955058004/Low-Cost-Earth-Brick-Construction-0955058007/plp> (accessed 11.18.22).
- Mostafa, M., Uddin, N., 2016. Experimental analysis of Compressed Earth Block (CEB) with banana fibers resisting flexural and compression forces. *Case Stud. Constr. Mater.* 5, 53–63. <https://doi.org/10.1016/j.cscm.2016.07.001>
- Nassar, S., Saliba, J., Saiyouri, N., 2023. Investigation of the possible valorization of Arcachon Bay dredged sediments in earth constructions. Presented at the CMSS23.
- Pacheco-Torgal, F., Jalali, S., 2012. Earth construction: Lessons from the past for future eco-efficient construction. *Constr. Build. Mater.* 29, 512–519. <https://doi.org/10.1016/j.conbuildmat.2011.10.054>
- Salmerón, A., Rumi, R., Langseth, H., Nielsen, T., Madsen, A., 2018. A Review of Inference Algorithms for Hybrid Bayesian Networks. *J. Artif. Intell. Res.* 62, 799–828. <https://doi.org/10.1613/jair.1.11228>
- Taalab, K., Corstanje, R., Zawadzka, J., Mayr, T., Whelan, M.J., Hannam, J.A., Creamer, R., 2015. On the application of Bayesian Networks in Digital Soil Mapping. *Geoderma* 259–260, 134–148. <https://doi.org/10.1016/j.geoderma.2015.05.014>
- Taallah, B., Guettala, A., Guettala, S., Kriker, A., 2014. Mechanical properties and hygroscopicity behavior of compressed earth block filled by date palm fibers. *Constr. Build. Mater.* 59, 161–168. <https://doi.org/10.1016/j.conbuildmat.2014.02.058>
- Tran, V.Q., 2021. Compressive Strength Prediction of Stabilized Dredged Sediments Using Artificial Neural Network. *Adv. Civ. Eng.* 2021, 1–8. <https://doi.org/10.1155/2021/6656084>
- Tran, V.Q., Do, H.Q., 2021. Prediction of California Bearing Ratio (CBR) of Stabilized Expansive Soils with Agricultural and Industrial Waste Using Light Gradient Boosting Machine 9.
- Uitdehaag, S.C.A., Donders, T.H., Kuiper, I., Wagner-Cremer, F., Sjerps, M.J., 2022. Use of Bayesian networks in forensic soil casework. *Sci. Justice* 62, 229–238. <https://doi.org/10.1016/j.scijus.2022.02.005>

Wiegerinck, W., Burgers, W., Kappen, B., 2011. Bayesian Networks , Introduction and Practical Applications.

XP P13-901 Compressed earth blocks fo walls and partitions : definitions - Specifications - Test methods - Delivery acceptance conditions [WWW Document], 2001. URL (accessed 11.18.22).