مجلة جامعة طرطوس للبحوث والدراسات العلمية _ سلسلة العلوم الهندسية المجلد (١٠) العدد (٥) ٢٠٢٦

Tartous University Journal for Research and Scientific Studies - engineering Sciences Series Vol. (10) No. (5) 2026

التنبؤ بمقاومة البيتون على الضغط باستخدام تقنيات التعلُّم الآلي

د. غصون اندراوس *

(تاريخ الإيداع ٢٠٢٦/٢/١ . قُبِل للنشر في ٢٠٢٦/٣/١١)

□ ملخّص□

يهدف هذا البحث إلى تطوير نموذج للتنبؤ بمقاومة البيتون على الضغط باستخدام تقنيات التعلّم الآلي، وبالاعتماد على مجموعة واسعة من البيانات التجريبية لخلطات بيتونية قياسية مأخوذة من قاعدة البيانات University of California, Irvine (UCI) Machine Learning Repository. تحوي هذه البيانات على المعلومات اللازمة لبناء النموذج وهي كمية المكوّنات الأساسية للخلطة البيتونية: الإسمنت، خبث الأفران العالية، الرماد المتطاير، الماء، الملدن، الحصويات الخشنة، الحصويات الناعمة، إضافة إلى مقاومة الضغط المُقاسة تجريبياً لعينات بيتونية أسطوانية، عند أعمار مختلفة تتراوح بين ٣ أيام إلى ٣٦٥ يوماً.

تمَّ تقسيم البيانات إلى مجموعة تدريب بنسبة 70% ومجموعة اختبار بنسبة 30%، ثم بناء أربعة نماذج تعلُّم آلي باستخدام لغة Python هي: الانحدار الخطي (Linear Regression)، الغابة العشوائية (Random Forest)، تعزيز التدرج (Gradient Boosting)، تعزيز التدرج الفائق Extreme Gradient Boosting (XGBoost). بعد ذلك تمَّ تقييم أداء النماذج الأربعة باستخدام مؤشرات الأداء مثل معامل التحديد (R^2)ومتوسط الخطأ التربيعي (MSE) والجذر التربيعي لمتوسط الخطأ (RMSE) لاختيار النموذج ذو الأداء الأفضل.

أظهرت النتائج تفوّق نموذج (XGBoost) من حيث الدقة والقدرة على تمثيل العلاقة غير الخطية بين مكوّنات الخلطة ومقاومة الضغط، مما يؤكد فعالية استخدام تقنيات التعلُّم الآلي– وخاصةً خوارزميات تعزيز التدرج (XGBoost)– في تحسين دقة التنبؤ بمقاومة البيتون، وتقليل الزمن والكلفة المرتبطة بالاختبارات المخبرية التقليدية، ويفتح مجالاً واسعاً للنماذج التنبؤية في التطبيقات الهندسية الحديثة.

الكلمات المفتاحية: مقاومة الضغط، التعلّم الآلي، التنبؤ، نماذج الانحدار، الغابات العشوائية، XGBoost .

* حاصلة على الدكتوراه – قسم الهندسة الإنشائية– كلية الهندسة المدنية– جامعة اللاذقية– اللاذقية – سورية.

E-mail:gosonandraws@latakia-univ.edu.sy

مجلة جامعة طرطوس للبحوث والدراسات العلمية _ سلسلة العلوم الهندسية المجلد (١٠) العدد (٥) ٢٠٢٦

Tartous University Journal for Research and Scientific Studies - engineering Sciences Series Vol. (10) No. (5) 2026

Prediction of Concrete Compressive Strength Using Machine Learning Techniques

Dr. Ghousson Andrawes*

(Received 1/2/2026 . Accepted 11/3/2026)

□ ABSTRACT □

This study aims to develop a predictive model for estimating the compressive strength of concrete using machine learning techniques, based on a large experimental dataset of standard concrete mixtures obtained from the UCI Machine Learning Repository database. The dataset contains all the necessary information for model development, including the quantity of the main concrete components: cement, blast furnace slag, fly ash, water, superplasticizer, coarse aggregate, fine aggregate, in addition to the experimentally measured compressive strength of cylindrical concrete samples at different ages ranging from 3 to 365 days.

The dataset was divided into a training set (70%) and a testing set (30%). Subsequently, four machine learning models were developed using the Python programming language, namely: Linear Regression, Random Forest, Gradient Boosting, and Extreme Gradient Boosting (XGBoost). The performance of these models was evaluated using several statistical metrics, including the coefficient of determination (R^2), mean squared error (MSE), and root mean squared error (RMSE), in order to identify the most accurate predictive model.

The results demonstrated the superiority of the XGBoost model in terms of prediction accuracy and its ability to effectively capture the nonlinear relationship between the concrete mixture components and compressive strength. These findings confirm the effectiveness of machine learning techniques—particularly gradient boosting-based algorithms such as XGBoost—in improving the accuracy of compressive strength prediction, reducing the time and cost associated with conventional laboratory testing, and providing a reliable approach for predictive modeling in modern engineering applications.

Keywords: Compressive strength, Machine learning, Prediction, Regression models, Random Forest, XGBoost.

***PhD holder, Department of Structural Engineering, Faculty of Civil Engineering, Latakia University, Latakia, Syria. E-mail:gosonandraws@latakia-univ.edu.sy

مقدمة

يُعدّ البيتون من أكثر مواد البناء استخداماً في العالم نظراً لما يتمتع به من مزايا مقارنةً بالمواد الأخرى، لذلك من الضروري دراسة خصائصه الميكانيكية وفقاً لتقنيات التصميم المتقدمة، ومن أبرز هذه الخصائص المقاومة المميزة على الضغط والتي تُعتبر معياراً هاماً في تصميم ودراسة المنشآت البيتونية.

في السنوات الأخيرة ومع تطور الذكاء الاصطناعي، شاع استخدام نماذج التعلم الآلي في مختلف قطاعات الهندسة، كونها ملائمة لمجموعة واسعة من أنواع البيانات، وتتمتع بقدرة كبيرة على إدراك العلاقات المعقدة وغير المتوقعة بين خصائص مجموعات بيانات الإدخال والإخراج.

عادةً يتم استخدام بعض نماذج التعلم الآلي الشائعة للتنبؤ بمقاومة الضغط للبيتون بشكلٍ عام، مثل نموذج الغابات العشوائية ونماذج الانحدار التكيفي متعدد المتغيرات ونموذج (XGBoost) ونماذج التعلم الآلي الهجينة، بحيث يمكن لهذه النماذج أن تقدِّم محاكاة للخصائص الميكانيكية للمواد على نطاق واسع.

تناولت الكثير من الدراسات السابقة تقنيات التعلم الآلي وتطبيقها على البيتون لأهداف مختلفة، نذكر من هذه الدراسات:

- استخدم (Alkharisi & Dahish, 2025) خوارزميات التعلم الآلي XGBoost و Random Forest، للتنبؤ بمقاومة البيتون على الضغط، مع تقييم الخصائص الميكانيكية للبيتون الذي يحوي نفايات بلاستيكية. جمع الباحثان بيانات متنوعة تشمل نسب الإسمنت، الركام، الماء، المواد الإضافية، ونسبة النفايات البلاستيكية المستخدمة في الخلطة. تمت مقارنة أداء النموذجين في التنبؤ الدقيق بمقاومة البيتون وتحديد أيهما أكثر ملاءمة للتعامل مع البيانات غير التقليدية. أظهرت النتائج أن XGBoost تفوق على Random Forestفي دقة التنبؤ، مع تسجيل أعلى قيم لمعامل التحديد R^2 وأدنى أخطاء متوسطة (MAE) و(RMSE)، مما يعكس قدرة XGBoost على معالجة العلاقات غير الخطية بين مكونات البيتون ونسبة النفايات البلاستيكية ومقاومة الضغط. أوضحت هذه الدراسة أهمية استخدام نماذج متقدمة مثل XGBoost في التنبؤ بخصائص البيتون الحديثة بعد إعادة التدوير، مما يدعم الابتكار المستدام في البناء.

-استخدم (Alghamdi, 2023) الشبكات العصبية الاصطناعية Artificial Neural Network (ANN) كأداة فعالة للتنبؤ بمقاومة الضغط للبيتون، مع الاستفادة من بيانات مختلطة (Synthetic Data) لتدريب النموذج. ركّز الباحث على تجاوز محدودية البيانات التجريبية الحقيقية المتوفرة عبر إنشاء مجموعات بيانات صناعية إضافية تكمل العينات التجريبية، مما يسمح بتغطية أوسع للخلطات المختلفة. تمَّ تهيئة النموذج بتغذية الشبكة العصبية بمجموعة من المدخلات التي تمثل نسب المكونات الأساسية في البيتون، وتمَّ تدريب (ANN)على مزيج من البيانات التجريبية والاصطناعية، مع تمثيل نسب المكونات الأساسية. أظهرت النتائج أن (ANN) قادرة على التنبؤ بمقاومة البيتون بدقة جيدة، وتفوقت في العديد من الحالات على نماذج الانحدار التقليدية. كما كشف التحليل أن البيانات المختلطة حسّنت قدرة النموذج على التعميم عبر مجموعة أوسع من الخلطات البيتونية، مقارنة باستخدام البيانات الحقيقية فقط. وتوصلت الدراسة إلى أنَّ الاعتماد على بيانات اصطناعية محسّنة، عند دمجها مع البيانات الفعلية، يمكن أن يقلل من مشكلة نقص البيانات في تدريب نماذج التعلم الآلي، ويزيد من موثوقية التنبؤات في تصميم الخلطات البيتونية.

-استخدم (Li, 2023) خوارزمية XGBoost كأداة فعالة للتنبؤ بمقاومة الضغط للبيتون باستخدام تقنيات التعلم الآلي وتحليل البيانات، وقد اعتمد على مجموعة بيانات متاحة من مصادر أكاديمية تمَّ تحليلها باستخدام لغة البرمجة Python، إذ تمَّ فحص درجة الارتباط بين مختلف مكونات البيتون مثل الإسمنت، الماء، الركام، والمواد الإضافية وعلاقتها بمقاومة الضغط. ثم تمت مقارنة دقة أداء XGBoost مع خوارزميات أخرى شائعة في التنبؤ، مثل Support Vector Machine وDecision Tree، لتحديد أفضل نموذج تنبؤ. أظهرت النتائج أن XGBoost حقق أداءً متفوقاً في تقدير مقاومة البيتون مقارنة بالنماذج التقليدية، وذلك بفضل قدرته على التقاط العلاقات غير الخطية بين المدخلات والمخرجات. كما أوضحت الدراسة أهمية تحليل (أهمية الخصائص) التي يوفرها XGBoost في فهم تأثير المتغيرات المختلفة على المقاومة المتوقعة، مما يجعل النموذج ليس دقيقاً فحسب بل قابلاً للتفسير والتحليل الهندسي أيضاً.

-قدّم (Wang & Ni, 2020) تطبيقاً أساسياً لشبكات التغذية الأمامية متعددة الطبقات بهدف التنبؤ بالمقاومة الفعلية المُقاسة للبيتون على الضغط بعد ٢٨ يوماً من المعالجة، بدلاً من الاعتماد على المعادلات الإحصائية التقليدية. تمَّ استخدام الشبكة العصبية كخوارزمية قادرة على التعامل مع العلاقة غير الخطية والمعقدة بين العوامل المؤثرة في الخلطة ومقاومة البيتون. استخدم الباحثان شبكة عصبية متعددة الطبقات Multilayer Feedforward Neural Network (MFNN) مكوَّنة من طبقة إدخال تضم المتغيرات الأساسية، وطبقة مخفية لتحليل التفاعلات المعقدة، وطبقة إخراج واحدة للتنبؤ بالمقاومة. تمَّ تدريب النموذج على بيانات تجريبية واسعة، مع تحسين تدريجي للأوزان لتقليل الخطأ. أظهرت النتائج أنَّ نموذج الشبكة العصبية حقّق دقة تنبؤ أعلى بكثير مقارنةً بالطرق التقليدية مثل الانحدار الخطي، مع توافق جيد مع قوانين تصميم الخلطات المعروفة، كما أكدّت أنَّ (MFNN) توفر أداة سريعة وموثوقة للتنبؤ بمقاومة البيتون، مما يمهّد الطريق لتطبيقات التعلم الآلي اللاحقة في تحسين تصميم البيتون عالي الأداء واستخدام خوارزميات أكثر تقدماً مثل XGBoost وGradient Boosting.

-قدّم (Paude et al; 2023) دراسة حول خوارزميات التعلّم الآلي المختلفة لتقدير مقاومة البيتون المحتوي على الرماد المتطاير. أجرى الباحثون مقارنة بين دقة نماذج التعلّم الآلي المختلفة، بما في ذلك النماذج غير المُجمّعة (الانحدار الخطي المتعدد، وانحدار متجه الدعم) والنماذج المُجمّعة (انحدار Adaptive Boost، الغابة العشوائية، XGBoost، وانحدار Bagging). استخدم الباحثون مجموعة بيانات واسعة تضم ٦٣٣ نتيجة تجريبية من قيم مقاومة الضغط ثم أُجري تقييم الأداء باستخدام عدة مؤشرات، مثل متوسط الخطأ المطلق (MAE)، ومتوسط مربع الخطأ (MSE)، ومعامل التحديد (R^2)، ومتوسط النسبة المئوية للخطأ المطلق (MAPE)، والجذر التربيعي لمتوسط الخطأ (RMSE). أظهرت المقارنة أن نموذج XGBoost Regressor هو النموذج الأكثر موثوقية، حيث حقق أعلى معامل تحديد (R^2)بقيمة ٠,٩٥ . كذلك تمَّ استخدام تحليل الحساسية والتحليل البارامتري لتوفير فهم أعمق للعلاقة بين معاملات الإدخال والمقاومة، مما أتاح فهماً شاملاً لتأثير الرماد المتطاير والمعاملات الأخرى على التنبؤ بمقاومة الضغط.

-قدّم (Rathakrishnan et al; 2022) وآخرون دراسة للتنبؤ بمقاومة الضغط للبيتون عالي الأداء الذي يحوي نسبة كبيرة من خبث الأفران العالية (GGBS) كبديل للإسمنت، باستخدام نماذج التعلم الآلي المعزّزة

(Boosting Machine Learning)، بما في ذلك XGBoost ، CatBoost، وLightGBM. تمَّ تقييم أداء النماذج باستخدام مؤشرات دقيقة مثل R^2 و RMSE وMAE، وذلك بعد إجراء تحسين للنماذج باستخدام المعاملات الفائقة عبر Random Search. أظهرت النتائج أن نماذج الـ Boosting تفوقت بوضوح على النماذج التقليدية، حيث قدّمت أفضل تنبؤات دقيقة لمقاومة البيتون، وأكّدت قدرة هذه النماذج على التعامل مع العلاقات غير الخطية بين مكونات الخلطة ومقاومتها، ما يجعلها أدوات فعّالة لتصميم البيتون عالية الأداء في التطبيقات الهندسية الحديثة.

- استخدم (Sapkota et al; 2025) خوارزمية XGBoost لتحسين التنبؤ بمقاومة البيتون عالي الأداء، مع تحسين المعاملات الفائقة باستخدام خوارزميات ميتاهيورستيك مثل Leopard Seal، كما تمَّ تطبيق تحليل SHAP لتفسير تأثير كل متغير على التنبؤ، حيث تبيَّن أن الأسمنت والملدن الفائق هما الأكثر تأثيراً في تطوير مقاومة البيتون عالي الأداء. أظهرت النتائج أن النموذج المحسّن قادر على تحقيق دقة عالية (٠,٩٢) على بيانات الاختبار، مما يعزز موثوقيته في التطبيقات العملية.

- قدّم (Shaaban et al; 2025) دراسة تتضمن تحليلاً شاملاً لتطبيق نماذج التعلم الآلي المتقدمة في التنبؤ بمقاومة الضغط للبيتون عالي المقاومة، مع التركيز على مقارنة أداء عدة خوارزميات باستخدام بيانات تجريبية حقيقية. تشمل مدخلات النموذج المكونات الأساسية للخلطة مثل محتوى الإسمنت، السيليكا، الماء، الملدن الفائق، الرمل، الحصى، وعمر المعالجة، بينما تكون مقاومة الضغط هي المتغيّر الهدف. اختبرت الدراسة عدة خوارزميات، من الانحدار الخطي إلى نماذج أكثر تطوراً مثل XGBoost، Random Forest، Support Vector Regression (SVR)، وK-Nearest Neighbors (KNN) ، بهدف تقييم قدرتها على التنبؤ بمقاومة الضغط بدقة عالية. أظهرت النتائج أن XGBoost قدّم أفضل أداء، مع أعلى قيمة لمعامل التحديد R^2 وأدنى أخطاء MAE وMSE. استخدم الباحثون أيضاً تحليل SHAP لتفسير تأثير كل متغير، حيث برز عمر المعالجة والكمية النسبية لكل مكون كعوامل أساسية. أوضحت الدراسة أن دمج تقنيات التعلم الآلي المتقدم مع تقنيات التحليل التفسيري يوفّر أداة قوية لتصميم بيتون عالي المقاومة وتوقع مقاومته بدقة.

-تناولت دراسة (Thapa, 2024) موضوع التنبؤ بمقاومة الضغط للبيتون باستخدام تقنيات التعلم الآلي، مستندة إلى بيانات تجريبية موثوقة تضم ٧٧٦ سجلًا من خلطات بيتونية مختلفة. تمَّ تقييم أداء عدة خوارزميات شائعة، منها Random Forest، KNN، SVM، وDecision Tree، باستخدام معامل التحديد (R^2)كمعيار رئيسي. أظهرت النتائج أن نموذج الغابة العشوائية حقق أفضل أداء بدقة تنبؤ عالية ($R^2 \approx 0.91$)، تلاه نموذج (KNN) ثم (SVM) وأخيراً Decision Tree. أوضحت هذه النتائج أنَّ خوارزميات التعلم الآلي تمتلك القدرة على التنبؤ بمقاومة البيتون بدقة عالية وفعالية أفضل من الطرق التحليلية التقليدية، مما يعزز إمكانيات دمجها في التطبيقات الهندسية للتنبؤ المبكر بمقاومة البيتون بدون الاعتماد على الاختبارات المخبرية المكلفة.

-تُعدّ الدراسة التي قدّمها (Yeh, 1998) من أوائل الدراسات العلمية التي اعتمدت الشبكات العصبية الاصطناعية (ANN) لتقدير مقاومة الضغط للبيتون عالي الأداء (HPC) High Performance Concrete. تناول البحث التعقيد الكبير لطبيعة البيتون عالي الأداء، واستخدم الباحث بيانات تجريبية من

خلطات بيتونية مختلفة لتدريب نموذج (ANN)، وتمت مقارنة أداء النموذج مع طرق الانحدار التقليدية. أظهرت النتائج أنَّ النموذج المبني باستخدام (ANN) هو الأكثر دقة في التنبؤ من نموذج الانحدار التحليلي، وأنَّ أساليب التعلُّم الآلي تمتلك قدرة كبيرة على التعامل مع العلاقات غير الخطية والمعقدة بين مكونات االبيتون ومقاومته على الضغط.

أهمية البحث وأهدافه:

يهدف البحث إلى تطوير نموذج تنبؤ دقيق لتقدير مقاومة البيتون على الضغط باستخدام تقنيات التعلُّم الآلي، حيث تمَّ بناء أربعة نماذج: الانحدار الخطي (Linear Regression)، الغابة العشوائية (Random Forest)، تعزيز التدرج (Gradient Boosting)، تعزيز التدرج الفائق (XGBoost)، ثمَّ مقارنة هذه النماذج عن طريق تحديد دقة التنبؤ (R^2) والجذر التربيعي لمتوسط الخطأ (RMSE)، وذلك لتقييم قدرتها على التنبؤ بمقاومة البيتون بشكل دقيق وموثوق، ثمَّ اختيار النموذج ذو الأداء الأفضل.

إنَّ التوصل إلى بناء نموذج دقيق لتوقع مقاومة الضغط للبيتون، يفتح المجال للتنبؤ بمقاومة أي خلطة بيتونية جديدة، ويُسهم في تقليل الكلفة والوقت في الاختبارات التجريبية المخبرية، كما أنَّه يشجِّع على التوسع في استخدام التقنيات القائمة على البيانات في الهندسة المدنية، ويدعم إمكانية دمج النموذج في أنظمة دعم القرار في المشاريع الهندسية.

منهجية البحث:

١- البيانات:

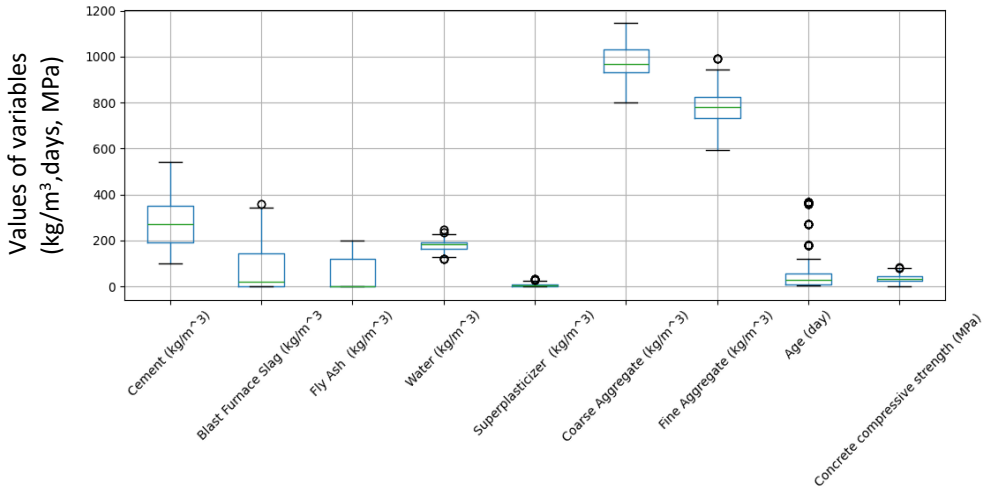
تمَّ استخدام مجموعة بيانات تجريبية مؤلفة من ١٠٢٨ سجلاً لخلطات بيتونية تجريبية منشورة من قِبل (Yeh,1998)، ومتاحة ضمن مستودع UCI Machine Learning Repository للتعلم الآلي. تتضمن قاعدة البيانات كمية المواد المُستخدمة في كل خلطة (الإسمنت، خبث الأفران العالية، الرماد المتطاير، الماء، الملدن، الحصويات الخشنة والناعمة)، بالإضافة إلى قيم مقاومة الضغط المُقاسة تجريبياً لعينات بيتونية أسطوانية، عند أعمار مختلفة تتراوح بين ٣ أيام إلى ٣٦٥ يوماً.

يبين الجدول (١) قيم المتوسط الحسابي والقيم الدنيا والقيم العظمى لكل مكوّن من مكونات الخلطات المُعتمدة في البحث والمأخوذة من سجّل البيانات.

الجدول (١) قيم المتوسط الحسابي والقيم الدنيا والقيم العظمى للبيانات المُعتمدة في الدراسة

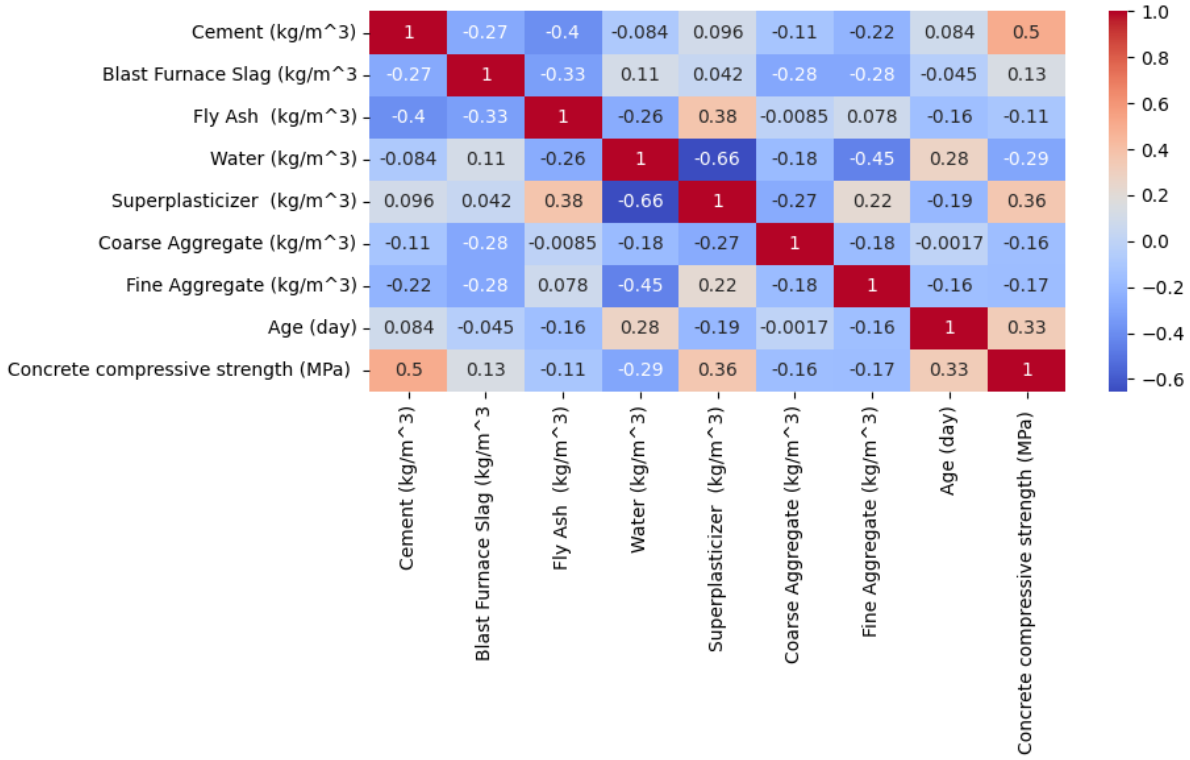
المكوّن (kg/m^3)	المتوسط الحسابي	القيمة الدنيا	القيمة العظمى
الإسمنت (Cement)	280.85	102	540
خبث الأفران العالية (Blast Furnace Slag)	74.04	٠	359.4
الرماد المتطاير (Fly Ash)	54.29	٠	200
الماء (Water)	181.54	121.75	247
الملدّن (Superplasticizer)	6.21	٠	32.2
الحصويات الخشنة (Coarse Aggregate)	972.77	801	1145
الحصويات الناعمة (Fine Aggregate)	773.74	594	992.60

تمَّ فحص البيانات والتأكد من سلامة القيم وعدم وجود بيانات مفقودة أو شاذة، وذلك باستخدام مقياس إحصائي يصف تشتت البيانات هو المدى بين الربيعين (IQR)، ويوضّح الرسم البياني الصندوقي boxplot المبين في الشكل (١)، التوزيع الإحصائي لمتغيرات البيانات.



الشكل (١) المخطط الصندوقي للبيانات المُعتمدة في الدراسة

بعد ذلك تمَّ فحص الترابط بين المتغيرات لتحديد العلاقات الأولية بينها وبين مقاومة البيتون، ويوضح الشكل (٢) مصفوفة الارتباط بين المتغيرات.



الشكل (٢) مصفوفة الارتباط بين المتغيرات

تمثِّل الأرقام داخل مربعات المصفوفة معامل الارتباط الخطي بين كل زوج من المتغيرات، حيث تتراوح قيمته بين (+1) و (−1). تشير القيمة (+1) إلى ارتباط إيجابي كامل، والقيمة (−1) إلى ارتباط سلبي كامل، والقيمة (0) إلى عدم وجود ارتباط خطي.

يوضح التحليل الإحصائي لمجموعة البيانات (الشكل (٢)) وجود علاقات متباينة بين قيم الإدخال ومقاومة البيتون على الضغط، حيث أظهرت مصفوفة الارتباط ما يأتي:

- يرتبط الإسمنت ارتباطاً إيجابياً بمقاومة الضغط بقيمة (0.5).
- يرتبط الملدن ارتباطاً إيجابياً بمقاومة الضغط بقيمة (0.36)، حيث يعمل على زيادة المقاومة عن طريق إنقاص كمية الماء اللازمة للخلطة.
- يرتبط الماء ارتباطاً سلبياً بمقاومة الضغط بقيمة (0.29−)، حيث تُقلل زيادة محتوى الماء من المقاومة.
- يرتبط عمر البيتون ارتباطاً إيجابياً بمقاومة الضغط بقيمة (0.33).

تمَّ تقسيم البيانات إلى مجموعتين: مجموعة من البيانات بنسبة 70% لتدريب النموذج، والمجموعة المتبقية من البيانات بنسبة 30% لاختبار مدى قدرة النماذج على التنبؤ بنتائج جديدة، وضمان دقة وموثوقية النماذج.

٢- نماذج التعلم الآلي:

تمَّ إنشاء أربعة نماذج للتنبؤ بمقاومة البيتون على الضغط، والتي تُعتبر من أكثر نماذج التعلم الآلي استخداماً في مسائل التنبؤ الهندسي:

- الانحدار الخطي (Linear Regression)
- الغابة العشوائية (Random Forest)
- تعزيز التدرج (Gradient Boosting)
- تعزيز التدرج الفائق (XGBoost)

تشمل مدخلات النموذج كميات المكوّنات الأساسية للخلطة البيتونية: الإسمنت، الإضافات الكيميائية، الماء، الملدّن، الحصويات الخشنة، الحصويات الناعمة، والعمر، بينما تكون مقاومة الضغط (MPa) هي المتغير المُستهدف.

أ- نموذج الانحدار الخطي (Linear Regression)

الانحدار الخطي هو نموذج إحصائي وتعلم آلي، يمكنه التنبؤ بقيمة المتغير الهدف من خلال إنشاء علاقة خطية بين بيانات الإدخال والمخرجات. تمَّ إعداد البرمجية الخاصة بهذا النموذج للتنبؤ بمقاومة البيتون على الضغط، باستخدام لغة Python. مع إظهار نتائج تقييم أداء هذا النموذج عن طريق تحديد دقة التنبؤ (R^2)ومتوسط الخطأ التربيعي (MSE) والجذر التربيعي لمتوسط الخطأ (RMSE) كما يلي:

```
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LinearRegression
from sklearn.metrics import r2_score, mean_squared_error
data = pd.read_excel("mix.xlsx")
X = data.iloc[:, 0:8]
y = data.iloc[:, 8]
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)
model = LinearRegression()
```

```
model.fit(X_train, y_train)
y_pred = model.predict(X_test)
r2 = r2_score(y_test, y_pred)
mse = mean_squared_error(y_test, y_pred)
print(r2)
print(mse)
print(rmse)
```

النتائج:

R^2=0.5701119595904522

MSE =113.71540236961769

RMSE =10.6637424185704

ب- نموذج الغابة العشوائية (Random Forest)

يعتمد هذا النموذج على مبدأ التعلّم التجميعي، حيث يتم إنشاء العديد من أشجار القرار باستخدام عينات عشوائية من البيانات ومجموعة عشوائية من المتغيرات، ثم يتم الحصول على التنبؤ النهائي بأخذ متوسط مخرجات الأشجار (في حالة الانحدار). تمَّ إعداد البرمجية الخاصة بهذا النموذج للتنبؤ بمقاومة البيتون على الضغط، باستخدام لغة Python كما يلي:

```
import pandas as pd
 from sklearn.model_selection import train_test_split
 from sklearn.ensemble import RandomForestRegressor
 from sklearn.metrics import r2_score, mean_squared_error
data = pd.read_excel("mix.xlsx")
X = data.iloc[:, 0:8]
y = data.iloc[:, 8]
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)
model = RandomForestRegressor(n_estimators=100, random_state=42)
model.fit(X_train, y_train)
y_pred = model.predict(X_test)
r2 = r2_score(y_test, y_pred)
mse = mean_squared_error(y_test, y_pred)
rmse = mse**0.5
print("R²:", r2)
print("MSE:", mse)
print("RMSE:", rmse)
```

النتائج:

R^2:

0.8790211013244125

MSE: 32.00173730821031

RMSE: 5.657007805210305

ت-نموذج تعزيز التدرج (Gradient Boosting)

هو أحد نماذج التعلم الآلي التجميعي ويُستخدم في التنبؤ والانحدار والتصنيف، ويعتمد على بناء نماذج جديدة بشكل تدريجي ومتسلسل، بحيث يُصحّح كل نموذج جديد الأخطاء المتبقية للنماذج السابقة. تمَّ إعداد البرمجية الخاصة بهذا النموذج للتنبؤ بمقاومة البيتون على الضغط، باستخدام لغة Python كما يلي:

```
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.ensemble import GradientBoostingRegressor
from sklearn.metrics import r2_score, mean_squared_error
data = pd.read_excel("mix.xlsx")
X = data.iloc[:, 0:8]
y = data.iloc[:, 8]
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)
model = GradientBoostingRegressor(n_estimators=100, learning_rate=0.1, max_depth=3,
random_state=42)
model.fit(X_train, y_train)
y_pred = model.predict(X_test)
r2 = r2_score(y_test, y_pred)
mse = mean_squared_error(y_test, y_pred)
rmse = mse**0.5
print("R²:", r2)
print("MSE:", mse)
print("RMSE:", rmse)
```

النتائج:

R²:

0.8941029182857808

MSE: 28.01224534050392

MSE: 5.292659571567391

ث- نموذج تعزيز التدرج الفائق XGBoost (Extreme Gradient Boosting)

هو نموذج متقدم للتعلّم التجميعي المعزّز، حيث تمَّ تطويره لتحسين أداء وسرعة وكفاءة نموذج Gradient Boosting التقليدي، مع إضافة تقنيات تحسين لتقليل الخطأ ومنع فرط التعلّم، ويُستخدم في مسائل الانحدار والتصنيف بدقة عالية جداً. تمَّ إعداد البرمجية الخاصة بهذا النموذج للتنبؤ بمقاومة البيتون على الضغط، باستخدام لغة Python كما يلي:

```
import pandas as pd
from sklearn.model_selection import train_test_split
from xgboost import XGBRegressor
from sklearn.metrics import r2_score, mean_squared_error
data = pd.read_excel("mix.xlsx")
X = data.iloc[:, 0:8]
```

```
y = data.iloc[:, 8]
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)
model = XGBRegressor(n_estimators=100, learning_rate=0.1, max_depth=3,
random_state=42, objective='reg:squarederror')
model.fit(X_train, y_train)
y_pred = model.predict(X_test)
r2 = r2_score(y_test, y_pred)
mse = mean_squared_error(y_test, y_pred)
rmse = mse**0.5
print("R²:", r2)
print("MSE:", mse)
print("RMSE:", rmse)
```

النتائج: R^2: 0.8966565827584453

MSE: 27.33674159131987

RMSE: 5.228454990847666

النتائج والمناقشة:

نبيّن فيما يلي نتائج مؤشرات الأداء للنماذج الأربعة التي تمَّ بناؤها باستخدام التعلم الآلي، وذلك لمقارنة جودة أدائها في التنبؤ وفي تمثيل العلاقة بين مكوّنات الخلطة البيتونية ومقاومة الضغط.

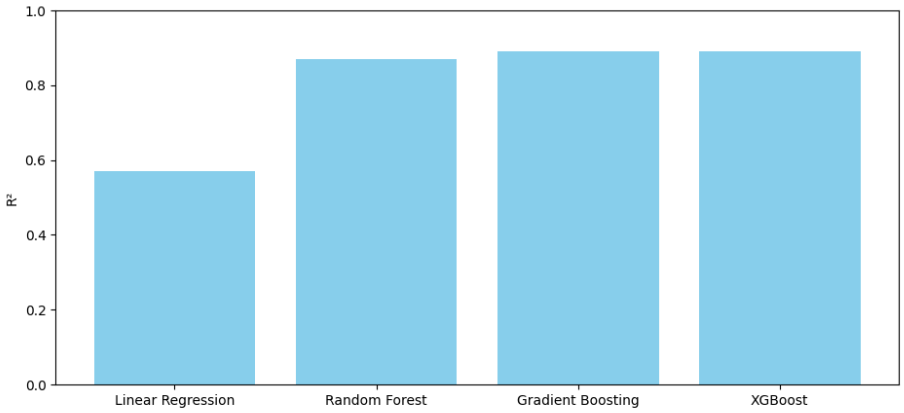
والنماذج المدروسة هي: الانحدار الخطي، الغابة العشوائية، تعزيز التدرج، تعزيز التدرج الفائق XGBoost .

ويبّيّن الجدول (٢) قيم المؤشرات المُستخدمة لتقييم أداء كل نموذج من النماذج الأربعة.

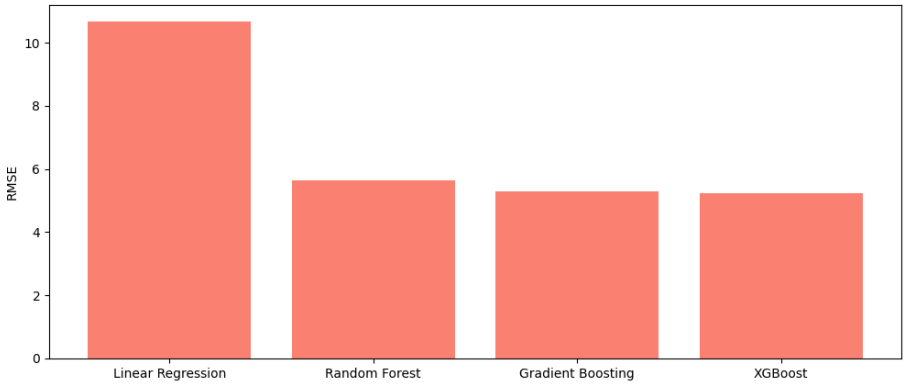
الجدول (٢) مؤشرات أداء النماذج التنبؤية المُستخدمة في الدراسة

اسم النموذج	دقة التنبؤ (R^2)	الجذر التربيعي لمتوسط الخطأ (RMSE)
الانحدار الخطي (Linear Regression)	**0.570**	**١٠,٦٦٣**
الغابة العشوائية (Random Forest)	**0.879**	**5.657**
تعزيز التدرج (Gradient Boosting)	**0.894**	**٥,٢٩٢**
تعزيز التدرج الفائق (XGBoost)	**٠,٨٩٦**	**٥,٢٢٨**

ويبين الشكل (٣) والشكل (٤) على التوالي رسماً بيانياً توضيحياً للفرق بين مؤشرات الأداء للنماذج الأربعة المُستخدمة.



الشكل (٣) قيم دقة التنبؤ (R^2) للنماذج الأربعة المُستخدمة



الشكل (٤) قيم الجذر التربيعي لمتوسط الخطأ $(RMSE)$ للنماذج الأربعة المُستخدمة

وبناءً على ما سبق و بإجراء المقارنة بين النماذج الأربعة نلاحظ الآتي:

❖ نموذج الانحدار الخطي: كان مؤشر الدقة الناتج ضعيفاً ومتوسط الخطأ كبيراً، أي أن النموذج لم يكن قادراً على تمثيل العلاقات غير الخطية بين المتغيرات لذلك ظهر أداؤه محدوداً، وبالتالي فإن نموذج الانحدار الخطي غير كافٍ للاستخدام في التنبؤ الدقيق بمقاومة البيتون على الضغط.

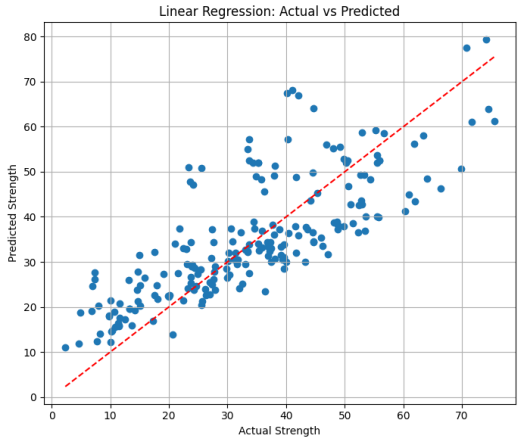
❖ نموذج الغابة العشوائية: حقّق تحسناً كبيراً في الدقة من جهة، وقيمة مقبولة جداً لمتوسط الخطأ من جهة أخرى، وبالتالي فإن النموذج يمتلك قدرة كبيرة على تمثيل العلاقات غير الخطية والتقليل من التحيّز، والتعامل مع التداخل بين المتغيرات، وبذلك حقّق أداءً أفضل من نموذج الانحدار الخطي.

لقد أظهر نموذج الغابة العشوائية قدرة جيدة على التنبؤ بقيم مقاومة الضغط، إلا أن دقته بقيت أقل من النماذج المعتمدة على تعزيز التدرج (Boosting)، بسبب اعتماده على تجميع أشجار مستقلة دون تصحيح تدريجي للأخطاء.

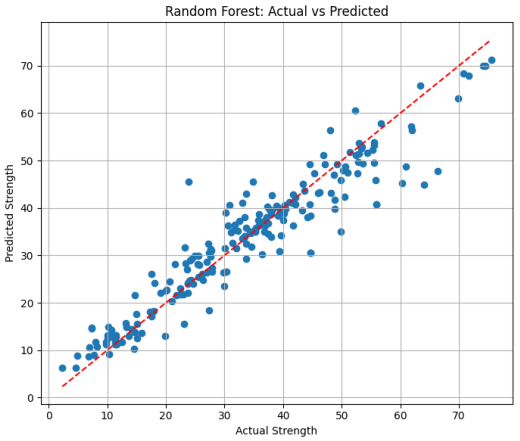
❖ نموذج تعزيز التدرج: أظهر تحسّناً إضافياً في الأداء مقارنة بنموذج الغابة العشوائية، من حيث ارتفاع دقة التنبؤ وانخفاض متوسط الخطأ، وذلك لأنه يعتمد على تصحيح أخطاء النماذج السابقة تدريجياً عبر عدة نماذج متتابعة مما يؤدي إلى بناء نموذج أكثر دقة عبر التكرار.

❖ نموذج XGBoost: حقّق أفضل النتائج، حيث أعطى أعلى دقة تنبؤ (0.896) وأدنى متوسط خطأ (5.228). يتميز هذا النموذج باستخدامه تقنيات التنظيم (Regularization) والمعالجة المتوازية مما يؤدي إلى تحسين الدقة وتقليل فرط التعلم، بالإضافة إلى قدرته على التحكم الدقيق في البيانات المعقدة والتعامل مع السلوك اللاخطي للبيتون، بالتالي يُعتبر نموذج XGBoostهو الأفضل والأكثر دقةً من بين كل النماذج السابقة.

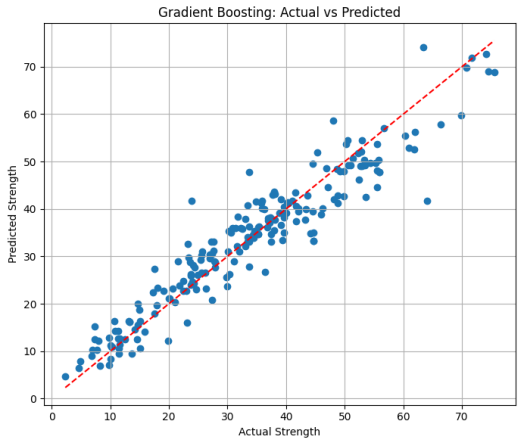
تبين الأشكال (5,6,7,8) على التوالي رسوماً بيانية توضِّح الفرق بين القيم الحقيقية والقيم المتوقعة لكل نموذج، وأيضاً تُظهر النموذج ذو الأداء الأفضل .



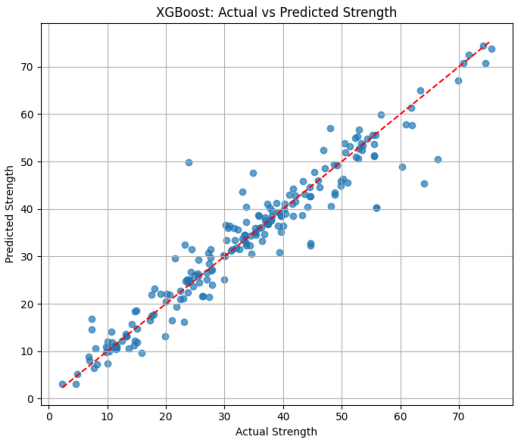
الشكل (٥) الفرق بين القيم الحقيقية والمتوقعة في نموذج الانحدار الخطي



الشكل (٦) الفرق بين القيم الحقيقية والمتوقعة في نموذج الغابة العشوائية



الشكل (٧) الفرق بين القيم الحقيقية والمتوقعة في نموذج تعزيز التدرج



الشكل (٨) الفرق بين القيم الحقيقية والمتوقعة في نموذج XGBoost

الاستنتاجات والتوصيات

الاستنتاجات

أثبت نموذج XGBoost كفاءة عالية في التنبؤ بمقاومة البيتون على الضغط بشكل دقيق وموثوق. وهذا يدل على أنّ النموذج يتمتع بدرجة عالية من الدقة والاستقرار، مما يزيد من موثوقيته للتنبؤ بخلطات جديدة، ويجعله مناسباً للاستخدام في الدراسات الهندسية والتطبيقات العملية الخاصة بتصميم وتحسين الخلطات البيتونية.

التوصيات

١- توسيع قاعدة البيانات عن طريق إدخال بيانات إضافية لخلطات بيتونية مختلفة، مثل الخلطات من البيتون عالي المقاومة.

٢- دمج الشبكات العصبية أو النماذج الهجينة لتحسين دقة التنبؤ.

٣- تجربة نماذج تعلّم متقدمة أخرى للتنبؤ، والتعامل مع تعقيدات أكبر في البيانات.

٤- الأخذ بعين الاعتبار تأثير درجة الحرارة والرطوبة وغيرها من العوامل البيئية خلال التدريب لتحسين دقة التنبؤ.

٥- إنشاء واجهة تطبيقية تمكِّن من إدخال مكونات الخلطة مباشرةً والحصول على مقاومة البيتون على الضغط.

المراجع

1- ALKHARISI, M.k; DAHISH, H.A. 2025, *Evaluation of Mechanical Properties of Concrete with Plastic Waste Using Random Forest and XGBoost Algorithms. Sustainability.Vol.17,No.24,10941.*

2- ALGHAMDI,S.J. 2023, *Prediction of Concrete's Compressive Strength via Artificial Neural Network Trained on Synthetic Data. Engineering, Technology & Applied Science Research.Vol.13,No.6*

٣- LI,G. 2023, *Prediction of Concrete Strength Using XGBoost. Highlights in Science, Engineering and Technology.Vol.39,311–314.*

4- NI,H.G; WANG,J.Z. 2000, *Prediction of Compressive Strength of Concrete by Neural Networks, Cement and Concrete Research.Vol.30,No.8,1245-1250.*

5- PAUDEL,S; PUDASAINI.A; SHRESTHA,R.K; KHAREL,E. 2023, *Compressive strength of concrete material using Machine Learning (ML)Techniques. Cleaner Engineering and Technology.Vol.15,No.4,100661.*

6- RATHAKRISHNAN,V; BEDDU,S.B; AHMAD,A.N. 2022, *Predicting compressive strength of high-performance concrete with high volume ground granulated blast-furnace slag replacement using boosting machine learning algorithms. Scientific Reports.Vol.12,No.9539.*

٧- SAPKOTA,S.C; PANAGIOTAKOPOULOU,C; DAHAL,D; BESKOPYLNY,A; DAHAL,S; ASTERIS,P.G. 2025, *Optimizing high-strength concrete compressive strength with explainable machine learning. Multiscale and Multidisciplinary Modeling, Experiments and Design.Vol.8 ,No.160,1-18.*

٨- SHAABAN,M; AMIN,M; SELIM,S; RIAD,I. M. 2025, *Machine learning approaches for forecasting compressive strength of high-strength concrete. Scientific Reports. Vol.15, No.25567.*

٩- THAPA,J. 2024, *Machine Learning Approaches for Predicting Concrete Compressive Strength. Journal of Advanced Research in Civil and Environmental Engineering.Vol.11,No.1, 9-20.*

10- YEH, I.C.1998, *Modeling of Strength of High-Performance Concrete Using Artificial Neural Networks. Cement and Concrete Research. Vol. 28,No.12,1797–1808.*

11- YEH, I.C.1998, *Concrete compressive strength [Dataset]. UCI Machine Learning Repository.*

https://archive.ics.uci.edu/ml/datasets/Concrete+Compressive+Strength