

تعزيز موثوقية التنبؤ بمقاومة الضغط للبيتون باستخدام خوارزميات التعلم الآلي وتقنيات التحليل التفسيري

د. غصون اندراوس*

ملخص

يهدف هذا البحث إلى تعزيز موثوقية نماذج التنبؤ بمقاومة الضغط للبيتون باستخدام خوارزميات التعلم الآلي، مع تحسين دقة التنبؤ وفهم تأثير مكونات الخلطة على مقاومة الضغط من خلال تقنيات التحليل التفسيري. تمّ في البداية بناء نموذج XGBoost كنموذج مرجعي أساسي باستخدام Python 3.10.11، ثمّ تحسين أدائه من خلال دمج مجموعة من الميزات المشتقة، مما أدى إلى تطوير نموذج محسّن بمعامل تحديد 0.93. استُخدمت تقنيات التحليل التفسيري، بما في ذلك تحليل أهمية المتغيرات، تحليل الحساسية، وتحليل "ماذا لو؟" لتفسير سلوك النموذج وتحديد مدى تأثير المتغيرات المختلفة على مقاومة الضغط للبيتون.

أظهرت النتائج أنّ محتوى الإسمنت وعمر البيتون، كانت الأكثر تأثيراً في تطور مقاومة الضغط بنسبة بلغت نحو 49%، إضافةً إلى كونها الأعلى حساسيةً بالمقارنة مع بقية المتغيرات المدخلة. في المقابل، كان تأثير الميزات المشتقة محدوداً نسبياً، مما يشير إلى أنّ أداء النموذج يعتمد بشكل رئيسي على المكونات الأساسية للخلطة وعمر البيتون، بينما تلعب الميزات المشتقة دوراً داعماً في تحسين دقة التنبؤ.

تؤكد نتائج البحث أهمية الدمج بين التنبؤ الدقيق والتحليل التفسيري، لتعزيز شفافية نماذج التعلم الآلي وموثوقية نتائجها، ودعم اتخاذ القرارات المتعلقة بتصميم الخلطات البيتونية. **الكلمات المفتاحية:** مقاومة الضغط، XGBoost، تعلّم آلي، تحليل الأهمية، تحليل الحساسية.

* عضو هيئة تعليمية (مديرة أعمال) - قسم الهندسة الإنشائية - كلية الهندسة المدنية - جامعة اللاذقية -

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

Enhancing the Reliability of Compressive Strength Prediction of Concrete Using Machine Learning Algorithms and Explainable Analysis Techniques

Dr. Ghousson Andrawes *

Abstract

This study aims to enhance the reliability of predictive models for concrete compressive strength using machine learning algorithms, while improving prediction accuracy and understanding the influence of mix constituents through explainable analysis techniques. Initially, an XGBoost model was developed as a baseline reference using Python 3.10.11. Its performance was subsequently improved by incorporating a set of derived features, resulting in an enhanced model with a coefficient of determination (R^2) of 0.93. Explainable analysis techniques, including feature importance analysis, sensitivity analysis, and “what-if” analysis, were employed to interpret the model behavior and assess the influence of different variables on concrete compressive strength.

The results showed that cement content and concrete age, had the greatest influence on the development of compressive strength, accounting for approximately 49%, and exhibited the highest sensitivity compared to the other input variables. In contrast, the derived features showed a relatively limited impact, indicating that the model's performance primarily depends on the fundamental mix components and concrete age, while the derived features play a supportive role in enhancing prediction accuracy.

The findings highlight the importance of integrating accurate prediction with explainable machine learning techniques to improve model transparency and reliability, thereby supporting informed decision-making in concrete mix design.

Keywords: compressive strength, XGBoost, Machine learning, importance analysis, sensitivity analysis.

* Faculty Member (Academic Rank: Business Manager), Department of Structural Engineering, Faculty of Civil Engineering, Latakia University, Latakia, Syria. E-mail: gosonandraws@latakia-univ.edu.sy

1- مقدمة

تُعَدُّ مقاومة الضغط من أهم الخواص الميكانيكية التي تتحكم في أداء البيتون، إلا أن تقديرها تجريبياً يتطلب وقتاً وكلفةً مرتفعة، مما أدى إلى تزايد الاعتماد على خوارزميات التعلم الآلي كأدوات فعّالة للتنبؤ بمقاومة الضغط اعتماداً على بيانات الخلطات، وعلى الرغم مما حققته هذه الخوارزميات من دقة تنبؤية عالية، إلا أن محدودية قابليتها للتفسير أظهرت الحاجة إلى فهم أعمق لدور المتغيرات المختلفة في عملية التنبؤ. انطلاقاً من ذلك، ركّزت الدراسات الحديثة على دمج نماذج التعلم الآلي مع تقنيات التحليل التفسيري مثل تحليل أهمية المتغيرات، تحليل الحساسية، وتحليل ماذا لو، بهدف تعزيز موثوقية النماذج وربط نتائجها بالسلوك الفيزيائي للبيتون.

يَعرّض هذا القسم أهم الدراسات السابقة التي تناولت التنبؤ بمقاومة الضغط للبيتون باستخدام التعلم الآلي، مع التركيز على الأساليب التفسيرية ودور الميزات المشتقة في تحسين أداء النماذج وفهم آليات عملها.

- قدّم الباحث (Almutairi, 2025) دراسة لتطوير إطار تعلّم آلي قابل للتفسير للتنبؤ بمقاومة الضغط للبيتون ذاتي الدمك، والذي يحوي ركّام معاد تدويره، مع دمج مواد إضافية مثل خبث أفران الصهر والرماد المتطاير. تمّ إنشاء قاعدة بيانات تجريبية مؤلفة من 400 عينة بيتونية، مع تطوير أربع خوارزميات تعلم آلي (SVR, RF, MLP, XGBoost) لتحسين المعاملات الفائقة. كان نموذج XGBoost أفضلها أداءً بدقة تنبؤ عالية ($R^2 \approx 0.96-0.98$). استُخدم التحليل التفسيري SHAP لتحديد تأثير المدخلات، وقد أظهرت النتائج أن المِلدن الفائق والإسمنت، هي المتغيرات الأكثر تأثيراً، بينما زيادة كمية الماء تؤثر سلباً على المقاومة. برهن النموذج القابل للتفسير على فعاليته في التقاط العلاقات غير الخطية بين متغيرات الخلطة ومقاومة الضغط، مما يدعم تحسين تصميم الخلطات البيتونية ذات الاستدامة. [1]

- استخدم الباحثان (Baseer & Ali, 2026) نماذج تعلّم آلي لتوقع مقاومة الضغط للبيتون المسامي (Pervious Concrete) بهدف تقليل الحاجة لاختبارات مخبرية. تم

تجميع 253 خلطة بيتونية، ثم استخدام مجموعة من خوارزميات التجميع مثل Random Forest، Extra Trees، AdaBoost، XGBoost، و Gradient Boosting Regressor (GBR) لبناء نماذج تنبؤية.

أظهرت النتائج أن GBR المحسن حقق أفضل أداء في التنبؤ بمقاومة الضغط مقارنةً بالخوارزميات الأخرى، مما يدل على قدرة نماذج التعلم الآلي على تقدير القوة الميكانيكية استناداً إلى مكونات الخلطة مثل نسبة الماء إلى الإسمنت، المسامية، ونسبة الركام. كما تمّ التحقق التجريبي من صحة النموذج باستخدام عينات مختبرية، وأكدت النتائج توافق التنبؤات مع القيم الحقيقية، مما يدعم استخدام التعلم الآلي كأداة مساعدة في تصميم الخلطات وتقليل الكلفة والوقت. [2]

- قدّم الباحثون (Fu, et al, 2025) دراسة لتطوير إطار تنبؤي لمقاومة الضغط للبيتون باستخدام نماذج التعلم الآلي القابلة للتفسير. استخدم الباحثون عدة خوارزميات مثل Gradient Boosting، Random Forest، و Neural Networks، مع 223 مجموعة من البيانات التجريبية، وتمّ ضبط المعاملات الفائقة باستخدام Bayesian optimization. أثبت النموذج CatBoost أنه الأفضل أداءً حيث حقق دقة عالية ($R^2 \approx 0.9388$) مع خطأ تنبؤ منخفض. تمّ استخدام تحليل SHAP لقياس مساهمة المتغيرات المختلفة، وأظهرت النتائج أن محتوى الإسمنت هو العامل الأكثر تأثيراً على مقاومة الضغط، يليه بالترتيب محتوى الماء، المواد المضافة، الرمال المتطاير، والركام. قدّمت هذه الدراسة أداة تفسيرية موثوقة لدعم تحسين تصميم الخلطات البيتونية. [3]

- استخدم الباحث (Li, 2023) خوارزمية XGBoost كأداة فعالة للتنبؤ بمقاومة الضغط للبيتون باستخدام تقنيات التعلم الآلي وتحليل البيانات. اعتمد الباحث على مجموعة بيانات متاحة من مصادر أكاديمية، حيث تمّ فحص درجة الارتباط بين مختلف مكونات البيتون مثل الإسمنت، الماء، الركام، والمواد الإضافية وعلاقتها بمقاومة الضغط. ثم تمّت مقارنة دقة أداء XGBoost مع خوارزميات أخرى شائعة في التنبؤ، مثل Support Vector Machine و Decision 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 المُدخلات والمُخرجات. كما أوضحت الدراسة أهمية تطبيق تحليل الأهمية التفسيري في فهم تأثير المتغيرات المختلفة على المقاومة المتوقعة. [4]

- قدّم الباحثون (Liu et al, 2023) دراسة حول تطوير منصة برمجية متكاملة للتنبؤ بمقاومة الضغط للبيتون العادي باستخدام تقنيات التعلم الآلي، بهدف تحسين الكفاءة وتقليل الزمن والكلفة المرتبطة بالاختبارات التجريبية التقليدية.

تمّت مقارنة عدة خوارزميات تعلم آلي، شملت أساليب الانحدار (مثل Ridge و Lasso و Elastic Net) وطرق متقدمة مثل (Support Vector Regression (SVR و (K-Nearest Neighbors (KNN، بالإضافة إلى نماذج Ensemble مثل Random Forest. أظهر التحليل أن نماذج التجميع (Ensemble models) حققت أداءً تنبؤي أعلى من النماذج الفردية، حيث بلغ معامل التحديد (R^2) للنماذج الفردية نحو 0.80، بينما تجاوزت قيمة R^2 في نماذج التجميع 0.95. كذلك ارتفعت دقة النموذج بشكل كبير، بعد تحسين المعاملات الفائقة باستخدام Grid Search Optimization، وكان نموذج GSXGBoost الأفضل أداءً. بعد ذلك طوّر الباحثون منصة برامج بواجهة رسومية (GUI) للاستفادة من النماذج التنبؤية، مما يساعد المهندسين في تصميم الخلطات وتوقع مقاومتها بسرعة وفعالية دون الاعتماد الكامل على اختبارات مختبرية مكلفة. [5]

- قام الباحثون (Lv et al, 2025) بتطوير نموذج تنبؤ موثوق لمقاومة الضغط للبيتون باستخدام خوارزمية XGBoost مدمجة مع تحليل التفسير SHAP، ما يجمع بين الدقة العالية والفهم الهندسي للعوامل المؤثرة. اعتمدت الدراسة على قاعدة بيانات ضخمة تضم 1078 عيّنة بيتونية، مع تحليل خمس متغيرات رئيسية مثل نسبة الماء إلى المواد الرابطة، العمر، المواد المضافة، الماء، ونسبة الرمل إلى الركام. حقّق النموذج أداءً قوياً بقيم $R^2 \approx 0.909$ و $RMSE \approx 4.65$ ، كما أظهر تحليل SHAP أن نسبة المواد الرابطة والعمر هما العاملان الأبرز في تحديد مقاومة الضغط، وأن تقسيم البيانات حسب العمر، يؤدي

إلى تحسّن إضافي في التنبؤ، مما يدعم استخدام النموذج في تحسين تصميم الخلطات عملياً. [6]

- استخدم الباحثون (Mahmood et al, 2025) نماذج التعلم الآلي للتنبؤ بمقاومة الضغط للبيتون عالي الأداء المحتوية على مسحوق الزجاج، مع التركيز على قابلية تفسير النماذج. قام الباحثون بتطوير عدة نماذج تنبؤية، ثم استخدموا تقنيات تفسيرية متقدمة هي SHAP و PDP و ICE لتحليل تأثير المتغيرات المختلفة على مقاومة الضغط. أظهرت نتائج تفسير النموذج أنّ محتوى الإسمنت، نسبة الماء إلى الإسمنت، عمر البيتون، ومحتوى مسحوق الزجاج هي من أكثر المتغيرات تأثيراً على مقاومة الضغط. كما بيّنت مخططات PDP و ICE العلاقات غير الخطية بين المتغيرات، وقدمت رؤية واضحة لكيفية تغيير المقاومة المتوقعة عند تعديل قيم متغيرات الخلطة، وهذا يتوافق مع مفهوم تحليل "ماذا لو" عملياً. [7]

- قام الباحثون (Wang et al, 2025) بتطوير نماذج تنبؤية متقدمة، ثمّ استخدام أدوات تفسيرية مثل SHAP لتحليل أهمية المتغيرات الفردية، بالإضافة إلى دراسة تأثير التفاعل بين المتغيرات وليس تأثير كل متغير بشكل منفرد فقط. أظهرت النتائج أنّ بعض المتغيرات الأساسية، مثل محتوى الإسمنت، نسبة الماء إلى المواد الرابطة، والعمر، لها تأثير مسيطر على الخواص الميكانيكية، إلا أنّ تأثيرها يتغير تبعاً لتفاعلها مع متغيرات أخرى مثل الإضافات المعدنية والركام. أوضح البحث أنّ تجاهل هذه التفاعلات قد يؤدي إلى تفسير غير مكتمل لسلوك النموذج، كما أظهر أنّ استخدام التعلم الآلي التفسيري لا يساهم فقط في تحسين دقة التنبؤ، بل يوفر أيضاً فهماً فيزيائياً أعمق لسلوك البيتون، مما يعزز موثوقية النماذج ويدعم تصميم خلطات أكثر كفاءة واستدامة. [8]

- استخدم الباحثون (Yang et al, 2025) نماذج تعلم آلي متعددة لتوقع مقاومة الضغط للبيتون الرغوي وتطبيق تحليل الحساسية لفهم تأثير كل متغير مُدخل على قوة الضغط. استخدم تحليل Shapley Additive Explanations (SHAP) كأداة حساسية لقياس مقدار تأثير كل متغير على مخرجات النموذج، حيث ساعد ذلك في تحديد ترتيب تأثير

المتغيرات مثل كثافة البيتون، نسبة الماء إلى الإسمنت، العمر، نسبة الركام، محتوى الملمن، ومعدل استبدال المواد المساعدة على المقاومة المتوقعة. أظهرت النتائج أن نموذج Gaussian Process Regression هو الأفضل أداءً، وأن كثافة البيتون ونسبة الماء إلى الإسمنت وعمر البيتون هي العوامل الأكثر حساسية في التنبؤ بمقاومة الضغط. أوضح البحث أن دمج التنبؤ الدقيق مع تحليل الحساسية يساهم في تفسير سلوك النموذج بشكل عميق. [9]

- تُعد الدراسة التي قَدَّمها الباحث (Yeh, 1998) من أوائل الدراسات العلمية التي اعتمدت الشبكات العصبية الاصطناعية (ANN) لتقدير مقاومة الضغط للبيتون عالي الأداء. استخدم الباحث بيانات تجريبية من خلطات بيتونية مختلفة لتدريب نموذج (ANN)، وتمت مقارنة أداء النموذج مع طرق الانحدار التقليدية. أظهرت النتائج أن النموذج المبني باستخدام (ANN) هو الأكثر دقة في التنبؤ من نموذج الانحدار التحليلي، وأن أساليب التعلم الآلي تمتلك قدرة كبيرة على التعامل مع العلاقات غير الخطية والمعقدة بين مكونات البيتون ومقاومته على الضغط. [10]

2- هدف البحث

يهدف هذا البحث إلى تعزيز موثوقية التنبؤ بمقاومة الضغط للبيتون، وذلك من خلال تطوير نموذج تعلم آلي محسّن باستخدام خوارزمية XGBoost بلغة Python، مع إضافة مجموعة من الميزات المشتقة لتحسين دقة التنبؤ ورفع أداء النموذج. كما يسعى البحث إلى توضيح تقنيات التحليل التفسيري لدراسة تأثير المكونات الأساسية والميزات المشتقة على مقاومة الضغط، وذلك لدعم اتخاذ قرارات تصميمية دقيقة وموثوقة للخلطات البيتونية.

3- مواد وطرق البحث

1.3. قاعدة البيانات

استُخدمت قاعدة البيانات Concrete Compressive Strength Dataset، والتي جُمِعت أساساً من قِبَل Yeh (1998)، وقد تمَّ الحصول عليها من مستودع التعلم الآلي UCI Machine Learning Repository [11].

تتضمن قاعدة البيانات 1028 خلطة بيتونية، حيث تحتوي كل خلطة على كمية المتغيرات الأساسية المُستخدمة في الدراسة وهي: الإسمنت، الماء، الحصىات الناعمة، الحصىات الخشنة، خبث الأفران العالية، الرماد المتطاير، المِلدن الفائق، عمر البيتون بالأيام، أما المتغير الهدف فهو مقاومة الضغط للبيتون. يبين الجدول (1) الملخص الإحصائي لمكونات الخلطات المُستخدمة في قاعدة البيانات المُعتمدة في هذا البحث.

الجدول (1) قيم المتوسط الحسابي والقيم الدنيا والقيم العظمى للبيانات

المكوّن (kg/m^3)	المتوسط الحسابي	القيمة الدنيا	القيمة العظمى
الإسمنت	280.85	102.00	540.00
خبث الأفران العالية	74.04	0	359.40
الرماد المتطاير	54.29	0	200.00
الماء	181.54	121.75	247.00
المِلدن	6.21	0	32.20
الحصىات الخشنة	972.77	801.00	1145.00
الحصىات الناعمة	773.74	594.00	992.60

وفقاً لما ورد في سجّل البيانات المتعلق بكل خلطة، تختلف قيمة المقاومة الفعلية للبيتون على الضغط من خلطة لأخرى، تبعاً لتغيّر خصائص المواد الداخلة في تركيب الخلطة وعمر البيتون الذي تراوح بين 3 أيام إلى 365 يوماً.

2.3. معالجة البيانات

تمَّ إجراء معالجة مسبقة للبيانات لضمان جودتها ومدى ملائمتها للتحليل، وتمَّ التحقق من القيم المفقودة والقيم الشاذة، بالإضافة إلى التأكد من توحيد وحدات القياس لجميع المتغيرات، كما تم تنظيم البيانات في صيغة رقمية مناسبة لإدخالها إلى نماذج التعلم الآلي.

3.3. بناء نموذج التعلم الآلي XGBoost (نموذج التعزيز التدريجي الفائق)

تم اعتماد خوارزمية XGBoost (Extreme Gradient Boosting) كنموذج أساسي للتعليق بمقاومة الضغط للبيتون. يتميز نموذج XGBoost بقدرته العالية على التعامل مع العلاقات غير الخطية والتفاعلات المعقدة بين المتغيرات، فهو نموذج متقدم للتعلم التجميعي المعزَّز، مع إضافة تقنيات تحسين لتقليل الخطأ ومنع فرط التعلم، ويُستخدم في مسائل الانحدار والتصنيف بدقة عالية جداً.

تمَّ تقسيم البيانات إلى مجموعة تدريب بنسبة 70% ومجموعة اختبار بنسبة 30%، ثم بناء نموذج XGBoost باستخدام لغة (Python)، وتقييم أداء النموذج عن طريق حساب مؤشرات الأداء مثل معامل التحديد (R^2)، متوسط مربع الخطأ (MSE) ومتوسط الخطأ المطلق (MAE).

تمَّ إدراج كود Python المستخدم في بناء نموذج XGBoost وتقييم أدائه، ضمن الملحق (1).

4.3. تحسين النموذج XGBoots

بهدف تحسين قدرة النموذج XGBoots على تمثيل العلاقات الفيزيائية بين مكونات الخلطة ومقاومة الضغط، تم إضافة مجموعة من الميزات المشتقة من المتغيرات الأساسية وهي: نسبة الإسمنت إلى الماء (Cement-to-Water Ratio). مجموع المواد الرابطة (Binder): يشمل الإسمنت، خبث الأفران العالية، والرماد المتطاير. نسبة الحصى (agg_ratio): أي نسبة الحصى الخشنة إلى الحصى الناعمة. تم دمج هذه الميزات المشتقة مع المتغيرات الأساسية للخلطة، لتشكيل مجموعة الميزات النهائية المستخدمة في تدريب النموذج.

كذلك تم إجراء ضبط للمعاملات الفائقة أي تحديد عدد الأشجار، العمق الأقصى لكل شجرة، ومعدل التعلم، حيث تؤثر هذه المعاملات بشكل مباشر على قدرة النموذج على التعلم من البيانات والتقاط العلاقات غير الخطية والمعقدة بين المتغيرات المستقلة ومقاومة الضغط.

تم إدراج كود Python المستخدم في تحسين النموذج XGBoost وتقييم أدائه، ضمن الملحق (2).

5.3. تقنيات التحليل التفسيري

تشير تقنيات التحليل التفسيري إلى مجموعة من الأساليب الكمية التي تهدف إلى فهم سلوك نماذج التعلم الآلي، وتفسير كيفية تأثير المتغيرات المدخلة على مقاومة الضغط للبيتون. تشمل تقنيات التحليل التفسيري المعتمدة في هذا البحث ما يلي:

1.5.3- تحليل أهمية المتغيرات (Feature Importance Analysis):

يُعدّ تحليل أهمية المتغيرات أحد أهم تقنيات التحليل التفسيري في نماذج التعلم الآلي، ويهدف إلى قياس مقدار مساهمة كل متغير مُدخل في التأثير على مقاومة الضغط، سواء كان من المتغيرات الأساسية أو من الميزات المشتقة.

من الجدير بالذكر أنه عند التنبؤ بمقاومة الضغط للبيتون، لا تكفي دقة النموذج وحدها لتقييم جودته، إذ إن النماذج عالية الدقة قد تعتمد على علاقات غير واقعية هندسياً، لذلك يُستخدم تحليل أهمية المتغيرات للتحقق من توافق سلوك النموذج مع المبادئ الفيزيائية والميكانيكية المعروفة لمكونات الخلطة البيتونية.

بما أن النموذج المُستخدم شجري (XGBoost/Gradient Boosting)، فقد تم استخراج أهمية المتغيرات مباشرة من النموذج المحسّن القائم على الخوارزميات الشجرية، حيث تُحسب أهمية كل متغير بناءً على عدد مرات استخدامه في تقسيم العقد داخل الأشجار، ومدى مساهمته في تقليل الخطأ أثناء التدريب.

تم إدراج كود Python المستخدم في تحليل أهمية المتغيرات الفردية للنموذج المحسّن (Enhanced model)، ضمن الملحق (3).

على الرغم من أن تحليل أهمية المتغيرات الفردية يوفر معلومات قيمة حول تأثير كل متغير على حدة، إلا أنه لا يوضح الدور النسبي للفئات المختلفة من المتغيرات، لذلك تم تقسيم المتغيرات إلى مجموعات فيزيائية وتركيبية ومشتقة، بهدف الانتقال من تفسير تأثير كل متغير على حدة إلى تقييم الأثر الكلي لكل مجموعة من المتغيرات، مما يتيح فهماً هرمياً لسلوك النموذج، ويعزز إمكانية ربط نتائج التعلم الآلي بالمنطق الهندسي التقليدي، مما يدعم موثوقية النموذج وقابليته للتطبيق العملي.

تم تقسيم المتغيرات إلى ثلاث مجموعات:

1- المتغيرات الفيزيائية:

تم تصنيف كمية الإسمنت والعمر ضمن مجموعة مستقلة تمثل المتغيرات الفيزيائية الأساسية، نظراً لارتباطهما المباشر بالآليات الفيزيائية والكيميائية الحاكمة لتطور مقاومة الضغط، ولا سيما تفاعلات الإماهة مع الزمن.

2- المتغيرات التركيبية:

تضم هذه المجموعة المكونات الكمية المباشرة للخلطة الببتونية، والتي تتحكم في البنية الحبيبية، ونسبة الفراغات، وقابلية التشغيل، وبالتالي تؤثر بشكل غير مباشر على مقاومة الضغط.

تضم هذه المجموعة: الماء، الحصىات، الرماد المتطاير، خبث الأفران العالية، الملدن الفائق.

3- المتغيرات المشتقة:

تمثل المتغيرات المشتقة علاقات مركبة بين المكونات الأساسية للخلطة، مثل نسبة الإسمنت إلى الماء، مجموع المواد الرابطة، ونسبة الحصىات، وهي تعكس مفاهيم هندسية مستخدمة في تصميم الخلطات الببتونية.

تم إدراج كود Python المستخدم في تحليل أهمية المتغيرات المجمعة للنموذج المحسن (Enhanced model)، ضمن الملحق (4).

2.5.3 - تحليل الحساسية (Sensitivity Analysis)

تحليل الحساسية هو تقنية كمية، تهدف إلى قياس استجابة مخرجات النموذج للتغير النسبي في قيمة كل متغير على حدة، مع تثبيت باقي المتغيرات عند قيمها المرجعية. تم إجراء تحليل الحساسية للنموذج المحسن من خلال زيادة قيمة متغير واحد فقط في كل مرة بنسبة 5% مع إبقاء باقي المتغيرات ثابتة دون تغيير، ثم حساب متوسط التغير في مقاومة الضغط المتوقعة. بعد ذلك تم ترتيب المتغيرات حسب أهميتها وعرض النتائج بيانياً لتوضيح أكثر المتغيرات تأثيراً على مقاومة الضغط للبيتون. تم استخدام تحليل الحساسية لفهم تأثير كل مكون من مكونات الخلطة على مقاومة الضغط المتوقعة للبيتون، مما يعزز تفسيرية النموذج ويؤكد توافقه مع المبادئ الهندسية التقليدية. تم إدراج كود Python المستخدم في تحليل الحساسية للنموذج المحسن (Enhanced model)، ضمن الملحق (5).

3.5.3- تحليل "ماذا لو؟" (What-if Analysis)

تحليل "ماذا لو؟" هو أسلوب تفسيري يُستخدم لدراسة سلوك النموذج تحت سيناريوهات افتراضية أو تغييرات محتملة في قيم المُدخلات. يتيح هذا التحليل دراسة مدى تأثير التغيرات في مكونات الخلطة البيتونية على مقاومة الضغط، مع إبقاء المتغيرات الأخرى ثابتة عند قيمها المرجعية.

يُستخدم تحليل "ماذا لو؟" لاستكشاف السيناريوهات المحتملة لتعديل الخلطة ومعرفة تأثيرها على مقاومة الضغط للبيتون، مما يدعم اتخاذ القرار المبني على بيانات موثوقة من نموذج التعلم الآلي.

تم إجراء تحليل "ماذا لو؟" باستخدام النموذج المحسن، مع اختيار الإسمنت والماء كمتغيرات رئيسية، واعتماد قيم مرجعية تمثل متوسط قيم جميع متغيرات الخلطات في قاعدة البيانات. تم تغيير محتوى الإسمنت والماء ضمن مجال $\pm 20\%$ مع تثبيت باقي المتغيرات دون تغيير، وإعادة حساب الميزات المشتقة المرتبطة بكل حالة. بعد ذلك، تم حساب مقاومة الضغط المتوقعة وتمثيل النتائج بيانياً لتحليل استجابة النموذج للتغيرات النسبية في المتغيرات المؤثرة.

تمَّ إدراج كود Python المُستخدم في تحليل "ماذا لو؟" للنموذج المحسَّن (Enhanced model)، ضمن الملحق (6).

4- النتائج ومناقشتها

4-1- تقييم أداء النموذج الأساسي والنموذج المحسَّن

تمَّ تقييم أداء النموذج الأساسي المبني باستخدام خوارزمية XGBoost وذلك باستخدام مؤشرات الأداء الإحصائية: معامل التحديد (R^2)، ومتوسط مربع الخطأ (RMSE) ومتوسط الخطأ المطلق (MAE). أظهرت النتائج أن النموذج الأساسي حقق قيمة R^2 مقدارها 0.896، مع قيم RMSE و MAE بلغت 5.228 و 3.821 على التوالي، مما يشير إلى قدرة جيدة على التقاط العلاقات بين مكونات الخلطة ومقاومة الضغط، مع وجود مجال لتحسين دقة التنبؤ.

كذلك تمَّ تقييم أداء النموذج المحسَّن Enhanced Model، والذي تم تطويره من خلال إضافة مجموعة من الميزات المشتقة وضبط المعاملات الفائقة. أظهرت النتائج ارتفاع في دقة التنبؤ بشكل ملحوظ حيث بلغت قيمة معامل التحديد R^2 للنموذج المحسَّن 0.931، مع انخفاض في قيم متوسط الأخطاء MAE و RMSE مقارنة بالنموذج الأساسي لتصبح 4.244 و 2.731 على التوالي، مما يعكس تحسناً كبيراً في قدرة النموذج على التنبؤ بمقاومة البيتون بشكل دقيق.


يُعرض الجدول (2) مقارنةً عدديةً لمؤشرات الأداء لكلٍّ من النموذج الأساسي والمحسن، في حين يوضَّح الشكل (1) المقارنة نفسها بصورة بيانية.

الجدول (2) مقارنة مؤشرات الأداء للنموذجين

النموذج	R^2	RMSE	AME
XGBoost	0.896	5.228	3.821
Enhanced model	0.931	4.244	2.731

أظهرت نتائج المقارنة بين النموذج الأساسي والنموذج المحسَّن تحسناً واضحاً في جميع مؤشرات الأداء الإحصائية. فقد ازدادت القدرة التفسيرية للنموذج بعد التحسين، حيث ارتفعت

قيمة معامل التحديد (R^2)، مما يدل على تمثيل أدق للعلاقة بين مكونات الخلطة ومقاومة الضغط. كما انخفضت قيم كل من RMSE و MAE، مما يعكس انخفاضاً ملحوظاً في أخطاء التنبؤ. ويُعزى هذا التحسن إلى إضافة الميزات المشتقة التي عززت تمثيل العلاقات غير الخطية بين المتغيرات، إلى جانب ضبط المعاملات الفائقة لنموذج XGBoost، مما أدى إلى تحسين قدرة النموذج على التعميم.



الشكل (1) مقارنة مؤشرات الأداء للنموذجين بيانياً

تشير النتائج السابقة إلى أن النموذج المحسن (Enhanced Model) أكثر ملاءمةً للتطبيقات الهندسية العملية التي تتطلب تنبؤات دقيقة وموثوقة لمقاومة الضغط.

4-2- التحليل التفسيري للنموذج المحسن

بعد مقارنة النموذجين من جهة الأداء وتقييم النتائج، تمّ التوجّه إلى تحليل النموذج المحسن باستخدام تقنيات التحليل التفسيري لفهم دور المتغيرات المختلفة في التنبؤ بمقاومة الضغط.


1- تحليل أهمية المتغيرات

تم تحليل أهمية المتغيرات الفردية في النموذج المحسن باستخدام مقياس تحليل الأهمية (Feature Importance)، وذلك بهدف تحديد المتغيرات الأكثر تأثيراً في التنبؤ بمقاومة الضغط.

يَعرض الجدول (3) القيم النسبية لأهمية المتغيرات في النموذج المحسّن، والتي تمّ الحصول عليها باستخدام مقياس تحليل الأهمية (Feature Importance)، بينما يوضّح الشكل (2) التمثيل البياني للتوزيع النسبي لهذه الأهمية.

الجدول (3) القيم النسبية لأهمية المتغيرات الفردية

المتغير / الميزة	الأهمية
الإسمنت	0.256406
العمر	0.232171
خبث الأفران العالية	0.098530
الملدن الفائق	0.098274
الماء	0.088442
نسبة الإسمنت إلى الماء	0.056879
الرماد المتطاير	0.048415
الحصويات الناعمة	0.045223
الحصويات الخشنة	0.028099
نسبة الحصويات	0.027775
مجموع المواد الرابطة	0.019786



الشكل (2) التوزيع النسبي لأهمية المتغيرات الفردية

أظهرت النتائج أنَّ محتوى الإسمنت وعمر البيتون يمتلكان أعلى أهمية نسبية، حيث يمثل كل منهما حوالي 25% و 24% من التأثير الكلي، مما يشير إلى الدور المحوري لهذين المتغيرين في تعزيز دقة التنبؤ بمقاومة الضغط، تليهما المتغيرات الأخرى مثل الماء، الحصى، والإضافات بمساهمات نسبية أقل، بينما أظهرت الميزات المشتقة تأثيراً نسبياً محدوداً.

على الرغم من أنَّ الميزات المشتقة لم تكن الأعلى تأثيراً، إلا أنها كانت فعالة في تنظيم العلاقات بين المتغيرات الأساسية وتقليل تشتت البيانات، وبالتالي تحسين أداء النموذج.

بعد تقييم المتغيرات الفردية، تمَّ تجميع المتغيرات في ثلاث مجموعات رئيسية (المتغيرات الفيزيائية، المتغيرات التركيبية، المتغيرات المشتقة)، وذلك لتوضيح الأهمية النسبية لكل مجموعة، كما هو مبين في الجدول (4).

الجدول (4) القيم النسبية لأهمية المتغيرات المجمعة

الأهمية	مجموعة المتغيرات
48.857%	المتغيرات الفيزيائية (الإسمنت، العمر)

40.698%	المتغيرات التركيبية (الماء، الحصىات، الرماد المتطاير، خبث الأفران العالية، الملدن الفائق)
10.444%	المتغيرات المشتقة (نسبة الإسمنت إلى الماء، مجموع المواد الرابطة، نسبة الحصىات)

أظهرت النتائج تأثير كل مجموعة من المتغيرات على مقاومة الضغط وفقاً لما يلي:

- شكّلت مجموعة المتغيرات الفيزيائية، والمتمثلة في محتوى الإسمنت وعمر الببتون، النسبة الأكبر من إجمالي أهمية المتغيرات بما يقارب 49%، مما يعكس الدور المحوري لهذين المتغيرين في تطور مقاومة الضغط، مما يدل على أن النموذج موثوق فيزيائياً.
- ساهمت المتغيرات التركيبية المرتبطة بمكونات الخلطة بنسبة تقارب 41% من إجمالي أهمية المتغيرات، مما يشير إلى أن النموذج حساس لتكوين الخلطة وليس فقط للإسمنت، وأنه لا يعمل كنموذج تبسيطي بل يلتقط التفاعلات المركبة بين مكونات الخلطة.
- كان تأثير الميزات المشتقة محدوداً نسبياً ونسبة تقارب 10% من الأهمية الكلية للمتغيرات. يشير ذلك إلى أن هذه الميزات لا تمثل العامل المسيطر في التنبؤ بمقاومة الضغط، إلا أنها تؤدي دوراً مكماً مهماً في تحسين دقة النموذج من خلال تعزيز قدرته على تمثيل العلاقات غير الخطية بين مكونات الخلطة، دون الإخلال بالمنطق الفيزيائي الحاكم لسلوك الببتون.

2- تحليل الحساسية


تم إجراء تحليل الحساسية للنموذج المحسن من خلال زيادة قيمة كل متغير من متغيرات الخلطة على حدة بنسبة 5%، مع تثبيت باقي المتغيرات دون تغيير، وذلك لدراسة مدى استجابة مقاومة الضغط المتوقعة لتغيرات محدودة في قيم المدخلات.

يبين الجدول (5) درجة حساسية كل متغير أو ميزة على مقاومة الضغط المتوقعة، بينما يعرض الشكل (3) التمثيل البياني لهذه الدرجات.

الجدول (5) درجة حساسية متغيرات الخلطة

المتغير / الميزة	الحساسية
------------------	----------

1.6447	الماء
1.3219	الإسمنت
1.3157	الحصويات الناعمة
1.1505	الحصويات الخشنة
0.3295	الملدن
0.2940	خبث الأفران
0.1437	الرماد المتطاير
0.1399	نسبة الإسمنت إلى الماء
0.0873	العمر
0.0705	نسبة الحصويات
0.0000	المواد الرابطة



الشكل (3) التمثيل البياني لدرجة حساسية متغيرات الخلطة


يُبيّن الجدول (5) والشكل (3) أنّ الإسمنت والماء يمتلكان أعلى درجات الحساسية، مما يجعلهما المتغيرين الأكثر تأثيراً على مقاومة الضغط المتوقعة، وبالتالي يعكس الدور الأساسي لهذين المكونين في تكوين البنية الداخلية للبيتون والتحكم في نسبة الإسمنت إلى الماء. تليهما الحصويات الناعمة والخشنة بدرجات حساسية مرتفعة نسبياً، حيث تسهم في ملء الفراغات وتوزيع الأحمال داخل الخلطة. أما الملدن والإضافات فقد أظهرت تأثيراً

متوسطاً، حيث يحسّن المِلدن قابلية التشغيل للخلطة، بينما تعمل الإضافات على تحسين التفاعل الكيميائي وملء الفراغات الدقيقة، مما يدعم تحسين الخواص الثانوية للبيتون. من جهة أخرى، تبيّن أنّ الميزات المشتقة (نسبة الإسمنت إلى الماء، نسبة الحصىات، العمر والمواد الرابطة)، لها تأثير محدود على المقاومة، مما يشير إلى أنّ دورها مكمل يهدف لتحسين دقة النموذج دون التأثير على السلوك الفيزيائي للخلطة البيتونية.

3- تحليل "ماذا لو؟"

تمّ إجراء تحليل "ماذا لو؟" على النموذج المُحسّن، حيث تمّ اختيار الإسمنت والماء كمتغيرين رئيسيين نظراً لأهميتهما في تحديد مقاومة الضغط للبيتون، مع تثبيت باقي متغيرات الخلطة عند قيمها المتوسطة.

يبين الشكل (4) التغير في مقاومة الضغط المتوقعة عند تعديل نسب الإسمنت والماء ضمن مجال يتراوح بين (-20%) و (+20%)، والنتائج عن تحليل "ماذا لو؟".



الشكل (4) تحليل "ماذا لو؟" تأثير الإسمنت والماء على مقاومة الضغط

أظهرت نتائج التحليل والموضحة بيانياً بالشكل (4) ما يلي:

- وجود علاقة طردية واضحة بين كمية الإسمنت ومقاومة الضغط، حيث أدت زيادة محتوى الإسمنت حتى (20%+) إلى ارتفاع تدريجي في مقاومة الضغط من حوالي 42 MPa إلى ما يقارب 50 MPa، في حين أدى تقليل كمية الإسمنت إلى انخفاض واضح في المقاومة. ويُعزى ذلك إلى الدور الأساسي للإسمنت في تكوين الهيكل الداخلي للعجينة الإسمنتية وتأثيره المباشر على نسبة الإسمنت إلى الماء.
- وجود علاقة عكسية قوية بين محتوى الماء ومقاومة الضغط، حيث أن تقليل كمية الماء بنسبة 20% أدى إلى زيادة مقاومة الضغط إلى نحو 55 MPa، في حين أن زيادة كمية الماء أدت إلى انخفاض تدريجي في المقاومة، مما يعكس الدور الحاسم للماء في التحكم بمسامية العجينة الإسمنتية وتكون المسارات الضعيفة داخلها.

5- الاستنتاجات والتوصيات

5-1- الاستنتاجات

- أظهر النموذج المحسن (Enhanced Model) أداءً متفوقاً مقارنةً بالنموذج الأساسي، مع زيادة دقة التنبؤ إلى 0.931 وانخفاض متوسط الأخطاء RMSE و MAE، مما يعكس فعالية إضافة الميزات المشتقة وضبط المعاملات الفائقة، ويعزز موثوقية التنبؤ بمقاومة البيتون على الضغط.
- أظهرت نتائج تحليل الأهمية والحساسية أن الإسمنت والماء هما المكونان الأكثر تأثيراً على مقاومة الضغط، بينما تلعب الحصويات والملدنات والإضافات دوراً ثانوياً أو مكملًا، مما يعزز فهم دور كل مكون، ويحول نموذج التعلم الآلي من أداة تنبؤية إلى أداة تفسيرية هندسية أيضاً.
- أظهر تحليل "ماذا لو؟" علاقة طردية واضحة بين محتوى الإسمنت ومقاومة الضغط، وعلاقة عكسية بين محتوى الماء ومقاومة الضغط، مما يتيح إمكانية محاكاة التغيرات النسبية في المكونات، والتنبؤ بتأثيرها دون الحاجة إلى إجراء تجارب مخبرية إضافية.

❖ توفر النتائج السابقة إطاراً متكاملًا لتقييم وتحسين النماذج التنبؤية لمقاومة الضغط للبيتون من جهة، وتبين أهمية دمج نماذج التعلم الآلي مع تقنيات التحليل التفسيري من جهة أخرى، مما يسهم في تعزيز موثوقية النماذج وربط مخرجاتها بالسلوك الفيزيائي للخلطة البيتونية، ويدعم اتخاذ قرارات تصميمية دقيقة وموثوقة لتطوير خلطات بيتونية أكثر كفاءة واستدامة.

5-2- التوصيات

- الاستفادة من النماذج المحسنة قبل إجراء التجارب المخبرية، لتقليل الوقت والتكاليف وزيادة موثوقية التنبؤ.
- محاكاة سيناريوهات التغييرات، لتقييم تأثير التغييرات النسبية في مكونات الخلطة على مقاومة الضغط، قبل تنفيذ الخلطات الفعلية.
- توسيع نطاق الدراسة ليشمل أنواعاً مختلفة من الإسمنت والإضافات.
- دراسة تأثير العوامل البيئية مثل درجات الحرارة والرطوبة، لتطوير نماذج أكثر شمولية وموثوقية.
- إنشاء منصات حاسوبية تمكن المهندسين والمصممين من التفاعل مع النموذج والتنبؤ بالنتائج، بدلاً من الاعتماد على الحسابات اليدوية أو التجارب المخبرية.

المراجع

- [1] ALMUTAIRI, A. 2025, Explainable machine learning based prediction of compressive strength in sustainable recycled aggregate self compacting concrete using SHAP analysis, Sustainability, Vol.17, No. 24, 11334.

- [2] BASEER, H. A., ALI, G.G.M.N. 2026, Machine learning-based compressive strength prediction in pervious concrete, Applied Sciences, Vol.7, No.1, p.3.
- [3] FU, H., ZHOU, X., XU, P., & SUN, D. 2025, Prediction of compressive strength of concrete using explainable machine learning models, Materials, Vol.18, No.21, P.5009.
- [4] LI, G. 2023, Prediction of Concrete Strength Using XGBoost, Highlights in Science, Engineering and Technology, Vol.39, 311–314.
- [5] LIU, K., ZHANG, L., WANG, W., ZHANG, G., XU, L., FAN, D., & YU, R. 2023, Development of compressive strength prediction platform for concrete materials based on machine learning techniques, Journal of Building Engineering, Vol.80, 107977.
- [6] LV, Q., ZHANG, J., ZHANG, L., ZHAO, H., & REN, J. 2025, Machine learning-based optimization of concrete strength using interpretable models, Materials Today Communications, Vol.47, 112872.
- [7] MAHMOOD, M. S., ALI, T., INAM, I., et al. 2025, Machine learning prediction and explainability analysis of high strength glass powder concrete using SHAP, PDP, and ICE, Scientific Reports, Vol.15, No.1, 22089.
- [8] WANG, J., DENG, J., LI, S., et al. 2025, Explainable machine learning for multicomponent concrete: Predictive modeling and feature interaction insights, Materials, Vol.18, No.19, 4456.
- [9] YANG, S., ZHONG, J., GAN, B., SUN, Y., BU, C., & ZHANG, M. 2025, Prediction and sensitivity analysis of foam concrete compressive strength based on machine learning techniques with hyper parameter optimization, Computer Modeling in Engineering & Sciences, Vol.144, No.3, 2943–2967.
- [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>

الملحق (1) كود بناء وتقييم أداء نموذج XGBoost

```

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
mae = mean_absolute_error(y_test, y_pred)
print("R²:", r2)
print("MSE:", mse)
print("RMSE:", rmse)
print("MAE:", mae)

```

الملحق (2) كود تحسين نموذج XGBoost باستخدام الميزات المشتقة وضبط المعاملات

```

import pandas as pd
from xgboost import XGBRegressor
from sklearn.model_selection import train_test_split,
RandomizedSearchCV, cross_val_score
from sklearn.metrics import r2_score, mean_squared_error
from scipy.stats import randint, uniform
import numpy as np
data = pd.read_excel("mix.xlsx")
X = data.iloc[:, 0:8].copy()
y = data.iloc[:, 8].copy()
X["cement_water"] = X.iloc[:, 0] / (X.iloc[:, 1] + 1e-5)
X["binder"] = X.iloc[:, 0] + X.iloc[:, 4] + X.iloc[:, 5]

```

```
X["agg_ratio"] = X.iloc[:, 2] / (X.iloc[:, 3] + 1e-5)
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3,
random_state=42)
xgb = XGBRegressor(objective="reg:squarederror", random_state=42)
param_dist = {
    "n_estimators": randint(600, 1201)
    "max_depth": randint(4, 7)
    "learning_rate": uniform(0.03, 0.04)
    "subsample": uniform(0.8, 0.2)
    "colsample_bytree": uniform(0.8, 0.2)
    "gamma": uniform(0, 0.2)
    "reg_alpha": uniform(0.2, 0)
    "reg_lambda": uniform(1, 1)}
random_search = RandomizedSearchCV(xgb,
param_distributions=param_dist, n_iter=40,
cv=5, scoring="r2", n_jobs=-1, verbose=1, random_state=42)
random_search.fit(X_train, y_train)
model = random_search.best_estimator_
y_pred = model.predict(X_test)
r2 = r2_score(y_test, y_pred)
rmse = np.sqrt(mean_squared_error(y_test, y_pred))
print("R2 =", r2)
print("RMSE =", rmse)
print("MAE =", mae)
```

الملحق (3) كود تحليل أهمية المتغيرات الفردية للنموذج المحسن Enhanced model

```
import joblib
import pandas as pd
import matplotlib.pyplot as plt
model = joblib.load("Enhanced model.pk1")
feature_names=model.feature_names_in_
importances=
model.feature_importances_
importance_df = pd.DataFrame({"Feature":
feature_names, "Importance":
importances}).sort_values(by="Importance", ascending=False)
plt.figure()
plt.barh(importance_df["Feature"], importance_df["Importance"])
plt.gca().invert_yaxis()
plt.xlabel("Importance")
```

```
plt.title("Feature Importance - Enhanced Model")
plt.show()
print(importance_df)
```

الملحق (4) كود تحليل أهمية المتغيرات المُجمّعة للنموذج المحسّن Enhanced model

```
import joblib
import pandas as pd
model = joblib.load("Enhanced model.pk1")
features = ['Cement (kg/m^3)', 'Blast Furnace Slag (kg/m^3)',
'Fly Ash (kg/m^3)', 'Water (kg/m^3)', 'Superplasticizer (kg/m^3)',
'Coarse Aggregate (kg/m^3)', 'Fine Aggregate (kg/m^3)', 'Age (day)',
'cement_water', 'binder', 'agg_ratio']
importances = model.feature_importances_
df = pd.DataFrame({ "feature": features, "importance": importances })
group_physical = ['Cement (kg/m^3)', 'Age (day)']
group_basic = ['Blast Furnace Slag (kg/m^3)', 'Fly Ash (kg/m^3)',
'Water (kg/m^3)', 'Superplasticizer (kg/m^3)', 'Coarse Aggregate
(kg/m^3)',
'Fine Aggregate (kg/m^3)']
group_derived = ['cement_water', 'binder', 'agg_ratio' ]
physical_importance =
df[df["feature"].isin(group_physical)][["importance"].sum()
basic_importance =
df[df["feature"].isin(group_basic)][["importance"].sum()
derived_importance =
df[df["feature"].isin(group_derived)][["importance"].sum()
total = physical_importance + basic_importance + derived_importance
print("Physical importance =", physical_importance)
print("Basic importance =", basic_importance)
print("Derived importance =", derived_importance)
print("Physical (%) =", physical_importance / total * 100)
print("Basic (%) =", basic_importance / total * 100)
print("Derived (%) =", derived_importance / total * 100)
```

الملحق (5) كود تحليل الحساسية للنموذج المحسّن Enhanced model

```
import joblib
import pandas as pd
import numpy as np
```

```
import matplotlib.pyplot as plt
model = joblib.load("Enhanced model.pk1")
data = pd.read_excel("mix.xlsx")
features = ['Cement (kg/m^3)', 'Blast Furnace Slag (kg/m^3)',
'Fly Ash (kg/m^3)', 'Water (kg/m^3)', 'Superplasticizer (kg/m^3)',
'Coarse Aggregate (kg/m^3)', 'Fine Aggregate (kg/m^3)', 'Age (day)',
data['cement_water'] = data['Cement (kg/m^3)'] / (data['Water (kg/m^3)']
+ 1e-5)
data['binder'] = data['Cement (kg/m^3)'] + data['Blast Furnace Slag
(kg/m^3)'] + data['Fly Ash (kg/m^3)']
data['agg_ratio'] = data['Coarse Aggregate (kg/m^3)'] / (data['Fine
Aggregate (kg/m^3)'] + 1e-5)
features += ['cement_water', 'binder', 'agg_ratio']
sensitivity = {}
delta = 0.05
y_pred_orig = model.predict(data[features])
for feature in features:
X_mod = data.copy()
X_mod[feature] = X_mod[feature] * (1 + delta)
y_pred_mod = model.predict(X_mod[features])
mean_change = np.mean(np.abs(y_pred_mod - y_pred_orig))
sensitivity[feature] = mean_change
sensitivity_df = pd.DataFrame.from_dict(sensitivity, orient='index',
columns=['Mean Change'])
sensitivity_df = sensitivity_df.sort_values(by='Mean Change',
ascending=False)
print(sensitivity_df)
plt.figure(figsize=(10,6))
plt.barh(sensitivity_df.index, sensitivity_df['Mean Change'])
plt.gca().invert_yaxis()
plt.xlabel('Average change in predicted compressive strength (MPa)')
plt.title('Sensitivity Analysis of Enhanced Model')
plt.show()
```

الملحق (6) كود تحليل "ماذا لو؟" للنموذج المحسن Enhanced model

```
import joblib
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
```

```

model = joblib.load("Enhanced model.pk1")
data = pd.read_excel("mix.xlsx")
data['cement_water'] = data['Cement (kg/m^3)'] / (data['Water (kg/m^3)']
+ 1e-5)
data['binder'] = data['Cement (kg/m^3)'] + data['Blast Furnace Slag
(kg/m^3)'] + data['Fly Ash (kg/m^3)'] * (
data['agg_ratio'] = data['Coarse Aggregate (kg/m^3)'] / (data['Fine
Aggregate (kg/m^3)'] + 1e-5)
features = ['Cement (kg/m^3)', 'Blast Furnace Slag (kg/m^3)',
'Fly Ash (kg/m^3)', 'Water (kg/m^3)', 'Superplasticizer (kg/m^3)',
'Coarse Aggregate (kg/m^3)', 'Fine Aggregate (kg/m^3)', 'Age (day)',
'cement_water', 'binder', 'agg_ratio']
sample = data[features].mean().to_frame().T
variables_to_test = ['Cement (kg/m^3)', 'Water (kg/m^3)']
deltas = np.linspace(-0.2, 0.2, 9)
plt.figure(figsize=(10,6))
for var in variables_to_test: predicted = []
for d in deltas:
temp = sample.copy()
temp[var] = temp[var] * (1 + d)
temp['cement_water'] = temp['Cement (kg/m^3)'] / (temp['Water
(kg/m^3)'] + 1e-5)
temp['binder'] = temp['Cement (kg/m^3)'] + temp['Blast Furnace Slag
(kg/m^3)'] + temp['Fly Ash (kg/m^3)']
temp['agg_ratio'] = temp['Coarse Aggregate (kg/m^3)'] /
(temp['Fine Aggregate (kg/m^3)'] + 1e-5)
y_pred = model.predict(temp[features])[0]
predicted.append(y_pred)
plt.plot(deltas*100, predicted, label=var)
plt.xlabel('Percentage change in variable (%)')
plt.ylabel('Predicted compressive strength (MPa)')
plt.title('What-if Analysis of Enhanced Model (Cement & Water)')
plt.legend()
plt.grid(True)
plt.show()

```

