

Penerapan Machine Learning Untuk Prediksi Kekuatan Beton

Darusman^{1}; Yonas Prima Arga Rumbyarso²*

1. Universitas Nusa Mandiri, Jl. Raya Jatiwaringin, Cipinang Melayu, Kota Jakarta Timur, DKI Jakarta 13620, Indonesia
2. Universitas Krisnadwipayana, Jl.Kampus Unkris Jatiwaringin, Pondok Gede, Kota Bekasi, Jawa Barat 13077, Indonesia

^{*})Email: 14230029@nusamandiri.ac.id

Received: 16 April 2025 | Accepted: 08 Desember 2025 | Published: 31 Desember 2025

ABSTRACT

Developing a predictive model for concrete strength uses three machine learning approaches, namely Linear Regression, Neural Network, and Multi-Layer Perceptron (MLP). The three models were tested using a dataset containing information about on concrete material and the results of concrete strength tests. The evaluation is carried out using Precision, Recall, F1-Score, Mean Squared Error (MSE), and R-squared metrics to measure the accuracy of model predictions. The research results show that the MLP model provides the best performance, demonstrating exceptionally high Precision, Recall and F1-Score, as well as low MSE and R-squared reaching 0.97. Compared with Neural Network and Linear Regression, the MLP model shows better generalization ability on test data. Although the other models also produced satisfactory results, the MLP proved to be more effective in predicting concrete strength with higher accuracy. This research indicates that the use of MLP in concrete strength prediction can enhance accuracy and efficiency in construction applications.

Keywords: Concrete Strength Prediction, Machine Learning, Model Evaluation

ABSTRAK

Pengembangan model prediksi kekuatan beton menggunakan tiga pendekatan machine learning, yaitu Linear Regression, Neural Network, dan Multi-Layer Perceptron (MLP). Ketiga model diuji menggunakan dataset yang berisi informasi mengenai komposisi material beton dan hasil uji kekuatan beton. Evaluasi dilakukan menggunakan metrik Precision, Recall, F1-Score, Mean Squared Error (MSE), dan R-squared untuk mengukur akurasi prediksi model. Hasil penelitian menunjukkan bahwa model MLP memberikan kinerja terbaik, dengan Precision, Recall, dan F1-Score yang sangat tinggi, serta MSE yang rendah dan R-squared mencapai 0.97. Dibandingkan dengan Neural Network dan Linear Regression, model MLP menunjukkan kemampuan generalisasi yang lebih baik pada data uji. Meskipun model-model lain juga memberikan hasil yang baik, MLP terbukti lebih efektif dalam memprediksi kekuatan beton dengan akurasi yang lebih tinggi. Penelitian ini mengindikasikan bahwa penggunaan MLP dalam prediksi kekuatan beton dapat meningkatkan akurasi dan efisiensi dalam aplikasi konstruksi.

Kata kunci: Prediksi Kekuatan Beton, Machine Learning, Evaluasi Model

1. PENDAHULUAN

Kekuatan beton merupakan salah satu parameter penting yang menentukan kualitas dan keselamatan struktur dalam konstruksi. Beton dengan kekuatan yang optimal memiliki peran signifikan dalam memastikan stabilitas dan daya tahan bangunan, sekaligus menjaga keselamatan pengguna bangunan tersebut [1][2]. Kekuatan beton yang rendah dapat menyebabkan kegagalan struktural, yang dalam jangka panjang dapat berpotensi menimbulkan kerugian, baik dari segi ekonomi maupun keselamatan [3][4]. Oleh karena itu, diperlukan suatu metode prediksi kekuatan beton yang akurat dan tepat untuk menjamin kualitas material dan keselamatan konstruksi yang lebih baik. Pengujian kekuatan beton secara tradisional sering kali bergantung pada metode fisik yang melibatkan pengujian destruktif. Metode ini tidak hanya memerlukan biaya yang tinggi, tetapi juga memakan waktu yang lama, serta dapat mengganggu efisiensi dalam produksi dan pelaksanaan proyek konstruksi [5][6]. Namun, seiring dengan perkembangan teknologi data dan analitik, khususnya dalam bidang kecerdasan buatan (*artificial intelligence*), muncul peluang untuk mengoptimalkan metode prediksi kekuatan beton dengan cara yang lebih cepat dan efisien [7][8]. Teknologi ini memungkinkan pengembangan model yang mampu mengidentifikasi pola-pola tersembunyi dalam data yang tidak dapat terdeteksi dengan metode pengujian konvensional, sehingga dapat meningkatkan akurasi dan efisiensi dalam prediksi kekuatan beton.

Seiring dengan pesatnya perkembangan teknologi *deep learning*, metode prediksi berbasis jaringan saraf tiruan (*neural networks*) telah menjadi pendekatan yang semakin banyak digunakan dalam analisis dan prediksi kekuatan beton [9][10]. Salah satu algoritma *deep learning* yang menonjol, yaitu *Multi-Layer Perceptron (MLP)*, memiliki kemampuan untuk menangani data yang kompleks dan multidimensional, yang sering kali ditemukan dalam studi material konstruksi [11][12]. Model-model ini mampu mengidentifikasi hubungan non-linear yang signifikan antara berbagai variabel, seperti jenis semen, bahan tambahan, umur pemanasan (*curing*), dan karakteristik material lainnya yang memengaruhi kekuatan beton [13][14]. Penelitian ini bertujuan untuk mengevaluasi kinerja beberapa algoritma *deep learning*, yaitu *regresi linier*, *neural network*, dan *MLP*, dalam memprediksi kekuatan beton. Pemilihan *MLP* dalam penelitian ini didasarkan pada kemampuannya dalam memproses data yang sangat kompleks dan non-linear, serta kemampuannya dalam menangani sejumlah besar variabel input yang sering muncul dalam analisis material konstruksi. *MLP* juga terkenal karena kemampuannya dalam menangani variasi data dalam jumlah besar dan menawarkan potensi besar dalam memodelkan hubungan yang kompleks antara fitur input dan output yang diinginkan [15][16].

Salah satu tantangan utama dalam penelitian prediksi kekuatan beton adalah ketergantungan yang tinggi pada pengujian fisik yang memerlukan biaya besar dan waktu yang cukup lama untuk proses analisis [17][18]. Oleh karena itu, penggunaan metode *deep learning* diharapkan dapat mengatasi permasalahan ini dengan menyediakan prediksi yang lebih cepat, lebih murah, dan lebih akurat, tanpa mengurangi ketelitian hasil. Lebih jauh lagi, penerapan model *deep learning* diharapkan dapat memberikan bantuan signifikan kepada para profesional konstruksi dalam merancang struktur secara lebih efisien dan mengurangi ketergantungan pada pengujian laboratorium yang mahal serta memakan waktu. Inovasi utama dalam penelitian ini adalah penerapan model *MLP* dalam memprediksi kekuatan beton, yang diharapkan dapat mengatasi kendala terkait kecepatan dan akurasi prediksi. Beberapa penelitian sebelumnya telah mengembangkan model prediksi menggunakan teknik *machine learning*, namun banyak di antaranya yang masih memiliki keterbatasan dalam hal akurasi dan efisiensi prediksi pada berbagai jenis beton [19][20]. Sebagian besar model ini belum dapat memanfaatkan data secara optimal dan masih bergantung pada metode konvensional yang lebih rumit dan memakan waktu. Kendala utama yang dihadapi dalam studi-studi

tersebut termasuk kesulitan dalam mengintegrasikan berbagai faktor yang mempengaruhi kekuatan beton, serta keterbatasan model dalam menangani data yang sangat kompleks [21][22]. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan dan menguji model MLP yang lebih efisien dan lebih tepat dalam memprediksi kekuatan beton. Melalui pendekatan ini, diharapkan dapat meningkatkan akurasi prediksi kekuatan beton dengan cara yang lebih efisien, cepat, dan hemat biaya.

Penelitian ini bertujuan untuk memperdalam pemahaman mengenai penerapan model *deep learning*, khususnya MLP, dalam prediksi material konstruksi seperti beton. Diharapkan, sistem yang dikembangkan dalam penelitian ini dapat memberikan kontribusi signifikan dalam perencanaan dan pelaksanaan proyek konstruksi, terutama dalam hal penghematan biaya, efisiensi waktu pengerjaan, serta pengambilan keputusan yang lebih informasional dan tepat terkait pemilihan material yang digunakan.



Sumber : Hasil Penelitian (2025)

Gambar 1 Sampel Pengujian Kekuatan Beton

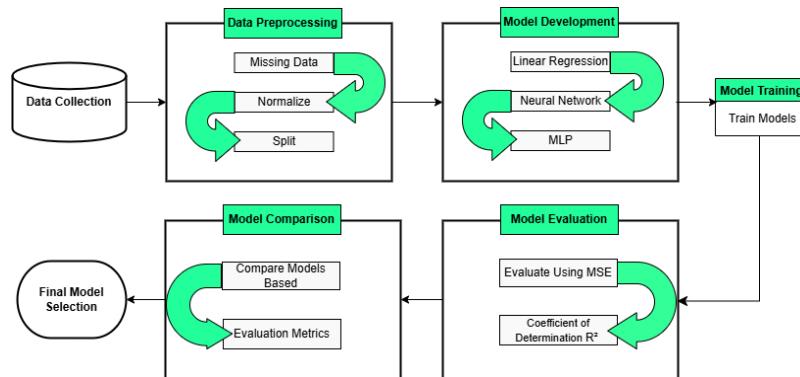
Gambar 1 pengujian kekuatan beton menggunakan mesin uji tekan, yang berfungsi untuk mengukur kekuatan kompresi beton dalam satuan *Megapascal (MPa)*. Mesin uji ini dilengkapi dengan sistem pengukuran otomatis yang menampilkan hasil uji secara langsung pada layar, seperti yang terlihat pada gambar di sebelah kanan. Pengujian ini merupakan bagian integral dalam evaluasi kualitas beton, di mana beton diuji hingga mencapai kegagalan untuk menentukan kekuatan kompresinya. Hasil uji menunjukkan nilai gaya sebesar 0.0004 kN yang diterapkan pada sampel, yang menunjukkan gaya awal yang sangat rendah. Nilai gaya maksimum yang diterapkan pada beton adalah 456.3 kN, yang tercatat sebelum beton mengalami kerusakan atau kegagalan. Selain itu, hasil uji juga menunjukkan bahwa kekuatan tekan beton mencapai 25.82 MPa, yang menggambarkan kapasitas beton dalam menahan tekanan. Hasil ini sangat penting untuk menilai apakah beton tersebut memenuhi standar kekuatan yang diperlukan dalam konstruksi dan memastikan daya tahan struktur yang akan dibangun.

2. METODE/PERANCANGAN PENELITIAN

2.1 Desain Penelitian

Penelitian ini menggunakan pendekatan eksperimen yang dilengkapi dengan analisis data untuk memprediksi kekuatan beton, berdasarkan berbagai fitur input yang mencakup material dan kondisi pengujian beton. Dataset yang digunakan dalam penelitian ini mencakup informasi terkait

jenis semen, bahan tambahan, umur pemanjangan (*curing*), jenis agregat, serta beberapa variabel lain yang dapat mempengaruhi kekuatan beton. Penelitian ini membandingkan tiga model prediksi yang berbeda untuk mengevaluasi efektivitas masing-masing model dalam menghasilkan prediksi yang akurat.

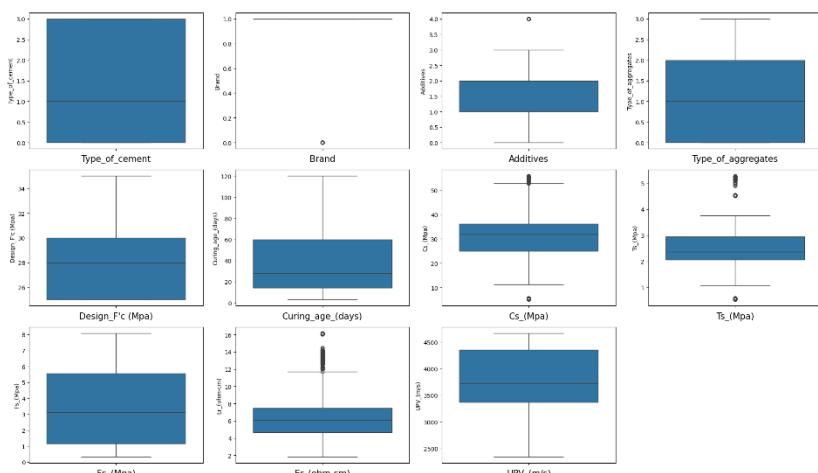


Sumber : Hasil Penelitian (2025)

Gambar 2 Desain Penelitian

2.2 Dataset

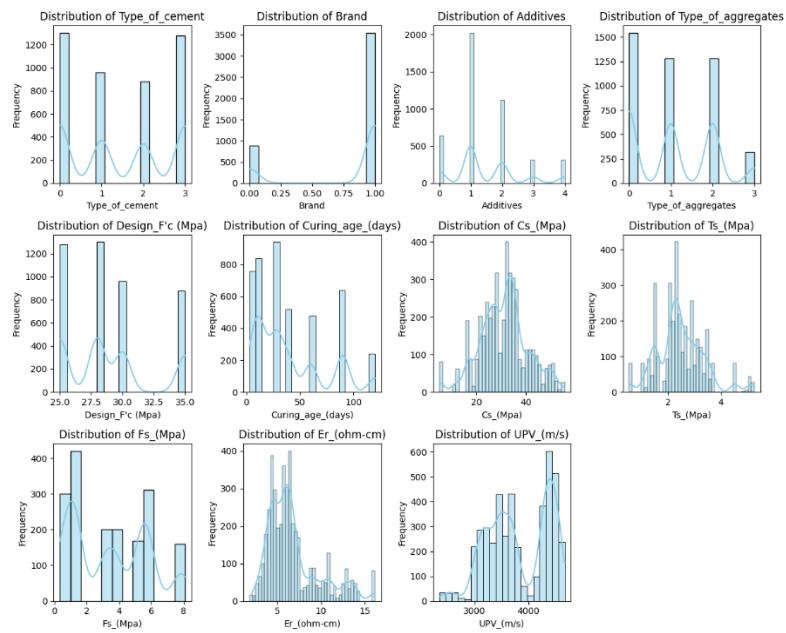
Dataset yang digunakan dalam penelitian ini adalah dataset yang berisi informasi terkait komposisi material beton dan hasil uji kekuatan beton. Dataset tersebut diambil dari file CSV yang mencakup fitur-fitur sebagai berikut:



Sumber : Hasil Penelitian (2025)

Gambar 3 Distribusi Data

Gambar 3 distribusi data parameter utama beton. *Type_of_cement*, *Brand*, *Additives*, dan *Type_of_aggregates* memiliki distribusi seragam, sementara *Design Fc (Mpa)*, *Curing age (days)*, dan *UPV (m/s)* menunjukkan distribusi merata tanpa banyak *outlier*. Parameter *Cs (Mpa)*, *Ts (Mpa)*, dan *Fs (Mpa)* memiliki beberapa *outlier*, begitu pula *Er (ohm-cm)* pada nilai tinggi. Visualisasi ini memberikan gambaran awal distribusi dan anomali data.



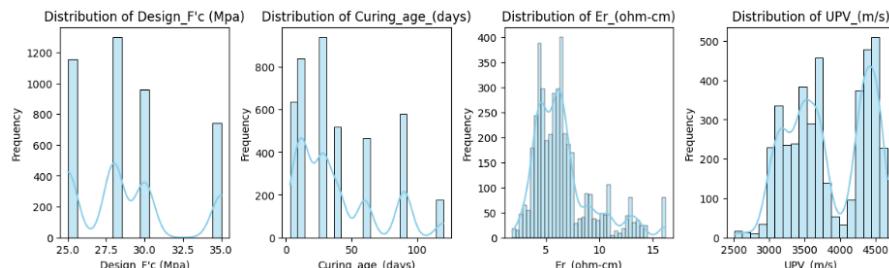
Sumber : Hasil Penelitian (2025)
Gambar 4 Distribusi Frekuensi dan Parameter

Gambar 4 distribusi frekuensi untuk berbagai parameter beton. Data kategori seperti *Type_of_cement*, *Brand*, *Additives*, dan *Type_of_aggregates* menunjukkan pola seragam, sedangkan data numerik seperti *Design Fc (Mpa)*, *Curing_age (days)*, *Cs (Mpa)*, *Fs (Mpa)*, dan *UPV (m/s)* menunjukkan pola distribusi yang bervariasi dengan puncak tertentu. Parameter *Er (ohm-cm)* dan *Ts (Mpa)* memiliki distribusi yang cenderung simetris dengan beberapa puncak frekuensi. Visualisasi ini memberikan wawasan awal untuk analisis lebih lanjut. Data tersebut kemudian dibersihkan untuk menghilangkan nilai yang hilang atau tidak valid dan kemudian dibagi menjadi dua bagian, yaitu data latih (*training data*) dan data uji (*test data*). Data latih digunakan untuk melatih model, sementara data uji digunakan untuk mengevaluasi kinerja model setelah dilatih.

2.3. Pra-pemrosesan Data

Sebelum digunakan dalam model, data mentah mengalami beberapa tahap *pra-pemrosesan*:

- Penanganan nilai yang hilang untuk mengatasi masalah nilai yang hilang pada kolom *Ts* dan *Fs*, yang dilakukan dengan metode penghapusan baris data yang tidak lengkap dalam dataset, digunakan pendekatan imputasi [23]. Nilai yang hilang diisi dengan rata-rata atau *median* berdasarkan fitur yang relevan.

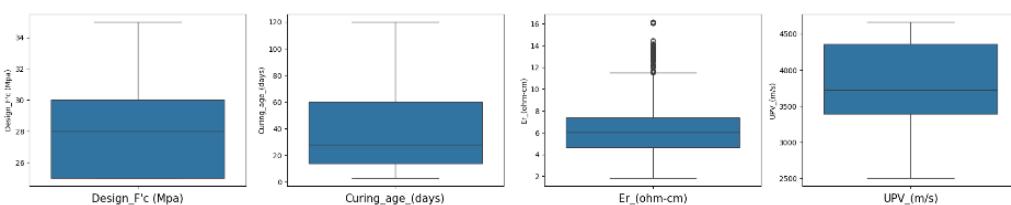


Sumber : Hasil Penelitian (2025)

Gambar 5 Distribusi Frekuensi

Gambar 5 distribusi frekuensi beberapa parameter utama beton *Design F'c (Mpa)* memiliki distribusi multimodal dengan puncak pada 25, 30, dan 35 Mpa; *Curing_age (days)* terkonsentrasi di bawah 50 hari dengan beberapa data di atas 100 hari *Er (ohm-cm)* memiliki puncak di sekitar 5-10 ohm-cm dengan beberapa *outlier* dan *UPV (m/s)* terdistribusi antara 2500 hingga 4500 m/s dengan puncak pada rentang 3500-4000 m/s. Distribusi ini memberikan wawasan awal tentang pola dan variasi dalam dataset.

- Normalisasi dan skala data karena beberapa fitur memiliki rentang nilai yang berbeda, data tersebut dinormalisasi menggunakan teknik standardisasi [24]. Ini memastikan bahwa semua fitur memiliki skala yang seragam dan mencegah model memberikan bobot lebih pada fitur dengan rentang nilai yang lebih besar.

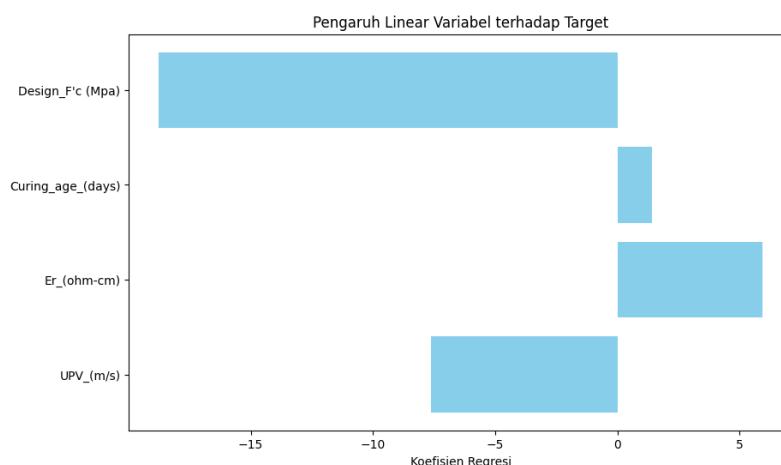


Sumber : Hasil Penelitian (2025)

Gambar 6 Distribusi Parameter

Gambar 6 distribusi data parameter utama beton dalam bentuk *boxplot*. *Design Fc (Mpa)* memiliki rentang 25-34 Mpa dengan median 30 Mpa, sementara *Curing_age (days)* berkisar 0-120 hari dengan median 50 hari. Parameter *Er (ohm-cm)* menunjukkan *outlier* di atas 12 ohm-cm, dan data utama berada di sekitar 7 ohm-cm. *UPV (m/s)* terdistribusi antara 2500-4500 m/s dengan median sekitar 4000 m/s. Visualisasi ini memberikan gambaran rentang nilai, distribusi, dan keberadaan *outlier*.

- Pembagian Dataset dibagi menjadi dua set:
 - Set Latih (*Training Set*) Digunakan untuk melatih model.
 - Set Uji (*Test Set*) Digunakan untuk menguji akurasi model setelah pelatihan.
 - Pembagian ini dilakukan dengan perbandingan 80% untuk data latih dan 20% untuk data uji, menggunakan fungsi *train test split* dari pustaka *sklearn*.



Sumber : Hasil Penelitian (2025)

Gambar 7 Variabel Kekuatan Beton

Gambar 7 hasil analisis *regresi linier* yang menggambarkan pengaruh variabel-variabel terhadap kekuatan beton (*Design F'c*). Variabel *Design F'c (Mpa)* memiliki pengaruh terbesar, diikuti oleh *Curing Age (days)* yang menunjukkan pengaruh moderat. Variabel *Er (ohm-cm)* dan *UPV (m/s)* memiliki pengaruh yang lebih kecil terhadap kekuatan beton. Grafik ini membantu untuk memahami variabel mana yang paling mempengaruhi kekuatan beton, memberikan dasar untuk pengambilan keputusan dalam perencanaan material beton.

2.4. Pengembangan Model

Penelitian ini melibatkan pengembangan dan evaluasi tiga model machine learning untuk memprediksi kekuatan beton, yaitu regresi *linier*, *neural network*, dan *MLP*. Regresi linier digunakan sebagai model dasar untuk memprediksi hubungan linier antara variabel input dan output, dengan asumsi adanya hubungan linier antara fitur yang ada dan kekuatan beton yang ingin diprediksi, serta digunakan sebagai acuan untuk membandingkan akurasi model-model yang lebih kompleks [11]. Model *neural network* menggunakan arsitektur jaringan saraf tiruan dengan satu lapisan tersembunyi dan fungsi aktivasi *ReLU*, serta proses pelatihan menggunakan metode optimisasi berbasis gradien, yaitu *Adam optimizer*, untuk meminimalkan kesalahan prediksi dan menangani hubungan *non-linier* yang lebih rumit antara variabel *input* dan *output* [25]. Sementara itu, model *MLP* merupakan varian lebih lanjut dari *neural network* dengan lebih banyak lapisan tersembunyi dan fungsi aktivasi *ReLU* pada setiap lapisan tersembunyi, serta fungsi aktivasi *sigmoid* atau *softmax* pada lapisan *output*, yang lebih kuat dalam menangani data dengan variasi tinggi dan hubungan *non-linier* untuk memodelkan pola kompleks dalam data [26].

2.5. Pelatihan Model

Setiap model dilatih dengan data latih menggunakan parameter yang telah ditentukan sebelumnya, termasuk penggunaan algoritma optimisasi (seperti *SGD* atau *Adam*) untuk memperbaiki bobot-bobot dalam jaringan berdasarkan kesalahan prediksi yang dihitung melalui fungsi kerugian (*loss function*) [27]. Proses pelatihan dilakukan dengan 100 *epoch* hingga model mencapai konvergensi.

2.6. Evaluasi Model

Setelah pelatihan, setiap model dievaluasi berdasarkan kinerja pada data uji dengan menggunakan dua metrik utama, yaitu *Mean Squared Error* (MSE), yang mengukur kesalahan rata-rata kuadrat antara nilai yang diprediksi dan nilai aktual dalam dataset uji, serta *Koefisien Determinasi* (R^2), yang mengukur sejauh mana model dapat menjelaskan variabilitas dalam data, di mana nilai R^2 yang lebih tinggi menunjukkan model yang lebih baik dalam memprediksi kekuatan beton [28], diikuti dengan analisis visualisasi menggunakan plot regresi untuk membandingkan prediksi model dengan nilai actual.

2.7. Perbandingan Model

Setelah evaluasi, hasil kinerja ketiga model dibandingkan untuk menilai model mana yang paling efektif dalam memprediksi kekuatan beton. Perbandingan ini dilakukan berdasarkan MSE dan R^2 untuk memastikan bahwa model yang dipilih tidak hanya memberikan prediksi yang akurat tetapi juga dapat diterapkan dalam konteks praktis.

2.8. Pengujian Hasil

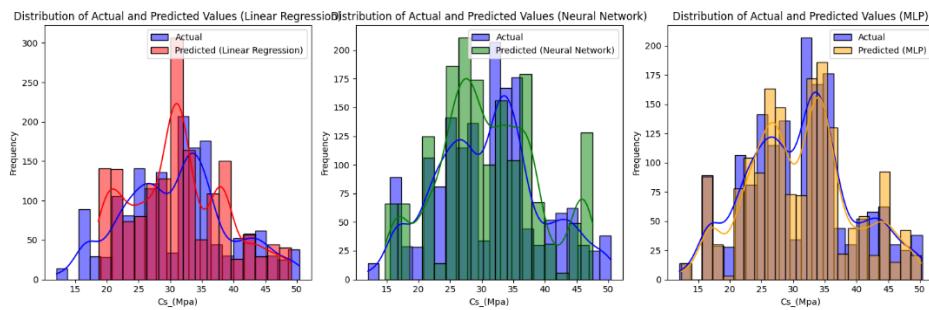
Setelah model dipilih, model tersebut diuji dengan menggunakan data yang tidak terlihat sebelumnya (data uji) untuk memastikan bahwa model yang dihasilkan dapat generalisasi dengan baik dan tidak *overfitting* pada data latih.

3. HASIL DAN PEMBAHASAN

Hasil analisis menunjukkan bahwa model yang digunakan memiliki kemampuan prediksi yang sangat baik, dengan tingkat kesalahan yang rendah dan variabilitas data yang sebagian besar dapat dijelaskan oleh model. Nilai *R-squared* sebesar 0.89 pada data uji menunjukkan bahwa model memiliki kinerja yang baik, dengan 89% dari variabilitas data dapat dijelaskan oleh model. Selain itu, nilai *R-squared* tambahan sebesar 0.97 mengindikasikan bahwa model mampu menjelaskan 97,37% dari variabilitas data kekuatan beton pada data uji, yang semakin memperkuat validitas model. Visualisasi hasil prediksi menunjukkan kecocokan yang sangat tinggi antara nilai aktual dan nilai prediksi, dengan sebagian besar data berada dalam interval kepercayaan yang wajar. Temuan ini menunjukkan bahwa model tidak hanya mampu menangkap pola kompleks dalam data pelatihan, tetapi juga menunjukkan kemampuan generalisasi yang sangat baik pada data yang sebelumnya tidak terlihat.

Selain itu, analisis perbandingan antara tiga model yang digunakan, yaitu *Regresi Linier*, *Neural Network*, dan *MLP*, menunjukkan bahwa model *MLP* memberikan hasil yang paling memuaskan. Model *Regresi Linier* menghasilkan MSE sebesar 11.34 dan *R-squared* sebesar 0.83, yang menunjukkan bahwa meskipun model ini memiliki kinerja yang baik, masih terdapat ruang untuk perbaikan, terutama dalam menangkap hubungan yang lebih kompleks dalam data. Sementara itu, model *Neural Network* menghasilkan *R-squared* sebesar 0.92 dan MSE sebesar 5.41, dengan nilai *R-squared* tambahan sebesar 0.97, yang menandakan bahwa model ini lebih akurat dalam memprediksi kekuatan beton dan mampu menjelaskan sebagian besar variabilitas data. Model *MLP* menunjukkan hasil terbaik dengan MSE sebesar 1.79 dan *R-squared* sebesar 0.97, yang menunjukkan bahwa model ini memberikan prediksi yang paling akurat dengan kemampuan generalisasi yang sangat baik pada data uji.

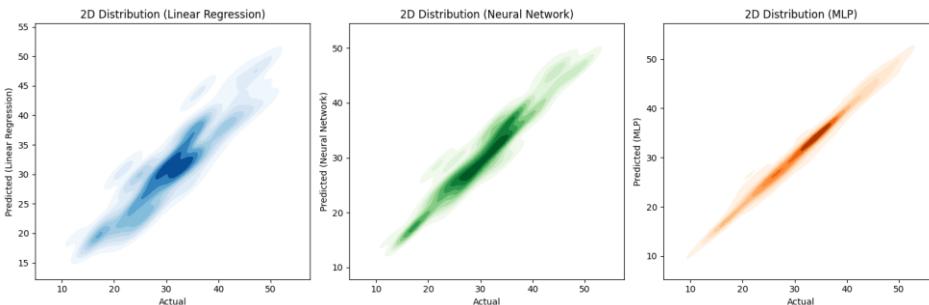
Beberapa *outlier* yang terdeteksi selama evaluasi dapat mengindikasikan adanya pengaruh faktor eksternal atau variasi dalam data yang tidak sepenuhnya tercermin dalam fitur yang digunakan. Outlier ini mungkin disebabkan oleh data yang tidak biasa atau kesalahan pengukuran dalam dataset. Analisis lebih lanjut terhadap *outlier* tersebut dapat memberikan wawasan yang berharga untuk meningkatkan akurasi model di masa mendatang. Oleh karena itu, disarankan untuk menggunakan dataset yang lebih besar dan lebih beragam, yang diharapkan dapat meningkatkan performa model secara keseluruhan. Penambahan jumlah data pelatihan dapat membantu model dalam memprediksi kekuatan beton dengan lebih akurat dan meningkatkan kemampuan generalisasi pada data yang lebih bervariasi. Di masa depan, eksplorasi terhadap teknik model yang lebih kompleks, seperti *deep learning* atau metode *ensemble*, dapat dipertimbangkan untuk lebih meningkatkan akurasi model.



Sumber : Hasil Penelitian (2025)

Gambar 8 Perbandingan Distribusi Nilai Aktual dan Prediksi

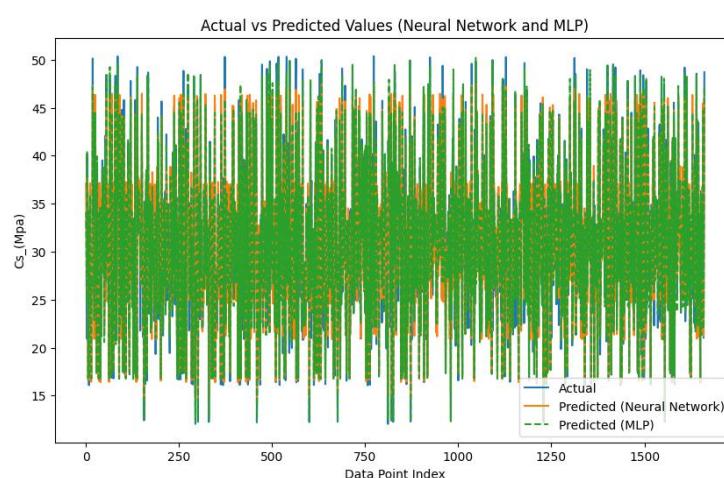
Gambar 8 distribusi nilai aktual dan prediksi dari tiga model *Linear Regression*, *Neural Network*, dan *MLP*. Model *Neural Network* dan *MLP* memberikan distribusi prediksi yang lebih mendekati nilai aktual, menunjukkan akurasi yang lebih baik dibandingkan dengan *Linear Regression*, yang cenderung menunjukkan kesalahan prediksi yang lebih besar.



Sumber : Hasil Penelitian (2025)

Gambar 9 Distribusi 2D Nilai Aktual dan Prediksi

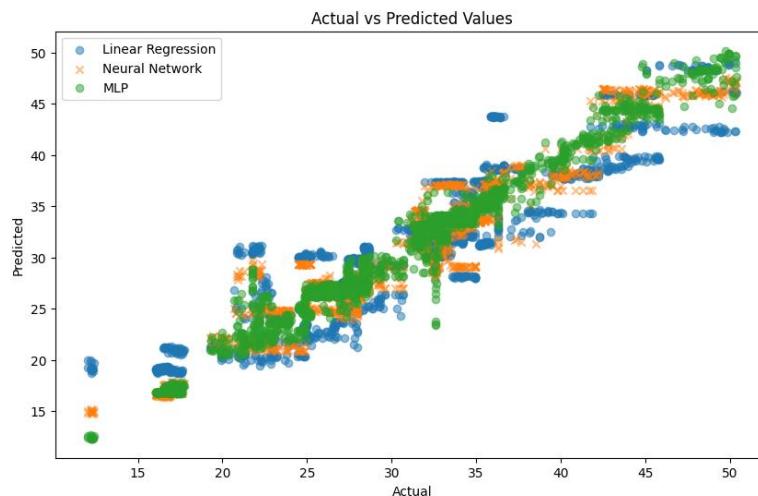
Gambar 9 distribusi 2D antara nilai aktual dan prediksi dari tiga model *Linear Regression*, *Neural Network*, dan *MLP*. *MLP* memberikan distribusi yang paling rapat dan akurat, diikuti oleh *Neural Network*, sementara *Linear Regression* menunjukkan distribusi yang lebih tersebar, mencerminkan kesalahan prediksi yang lebih besar.



Sumber : Hasil Penelitian (2025)

Gambar 10 Perbandingan Nilai Aktual dan Prediksi

Gambar 10 perbandingan antara nilai aktual dan prediksi kekuatan beton yang dihasilkan oleh model *Neural Network* (garis biru) dan MLP (garis oranye). Nilai aktual ditunjukkan dengan garis hijau, sedangkan prediksi dari kedua model diperlihatkan dengan garis putus-putus. Dari gambar ini, terlihat bahwa kedua model memberikan prediksi yang sangat mendekati nilai aktual, dengan MLP menunjukkan hasil prediksi yang sedikit lebih rapat dan konsisten dibandingkan *Neural Network*, yang memiliki sedikit fluktuasi.



Sumber : Hasil Penelitian (2025)

Gambar 11 Perbandingan Nilai Aktual dan Prediksi

Gambar 11 perbandingan antara nilai aktual dan prediksi dari tiga model *Linear Regression* (titik biru), *Neural Network* (titik oranye), dan MLP (titik hijau). Dari gambar ini, terlihat bahwa MLP memberikan prediksi yang paling rapat dan konsisten dengan nilai aktual, diikuti oleh *Neural Network* dan *Linear Regression* menunjukkan penyebaran yang lebih besar, menandakan adanya kesalahan prediksi yang lebih signifikan dibandingkan kedua model lainnya.

Tabel 1 Hasil Model Linear Regression

	Precision	Recall	F1-Score	Support
0	0.89	0.94	0.93	768
1	0.98	0.89	0.94	894
Accuracy			0.93	1662
Macro Avg	0.93	0.94	0.93	1662
Weighted Avg	0.94	0.93	0.93	1662

Sumber : Hasil Penelitian (2025)

Tabel 1 hasil evaluasi model *Linear Regression* berdasarkan metrik *Precision*, *Recall*, *F1-Score*, dan *Support* untuk dua kelas. Model ini menunjukkan *Precision* yang tinggi, terutama pada kelas 1 (0.98), dan *Recall* yang baik, terutama pada kelas 0 (0.94). *F1-Score* untuk kedua kelas adalah 0.93, menandakan keseimbangan antara *Precision* dan *Recall*. Model ini memiliki *Accuracy* sebesar 0.93, dengan nilai *Macro Avg* dan *Weighted Avg* masing-masing 0.93, menunjukkan performa yang konsisten di seluruh kelas. Secara keseluruhan, model *Linear Regression* memiliki kinerja yang baik dan dapat diandalkan dalam memprediksi kedua kelas.

Tabel 2 Hasil Model Neural Network

	Precision	Recall	F1-Score	Support
0	0.87	0.99	0.93	768
1	0.99	0.87	0.93	894
Accuracy			0.93	1662
Macro Avg	0.93	0.93	0.93	1662
Weighted Avg	0.94	0.93	0.93	1662

Sumber : Hasil Penelitian (2025)

Tabel 2 hasil evaluasi model *Neural Network* berdasarkan metrik *Precision*, *Recall*, *F1-Score*, dan *Support* untuk dua kelas (0 dan 1). Model ini menunjukkan *Precision* yang tinggi pada kelas 1 (0.99) dan kelas 0 (0.87), serta *Recall* yang sangat baik pada kelas 0 (0.99) dan kelas 1 (0.87). *F1-Score* untuk kedua kelas adalah 0.93, menunjukkan keseimbangan yang baik antara *Precision* dan *Recall*. Model ini memiliki *Accuracy* sebesar 0.93, dengan *Macro Avg* dan *Weighted Avg* masing-masing 0.93, menunjukkan kinerja yang konsisten. Secara keseluruhan, model *Neural Network* memiliki kinerja yang sangat baik, dengan performa yang solid di seluruh kelas.

Tabel 3 Hasil Model MLP

	Precision	Recall	F1-Score	Support
0	0.95	0.99	0.97	768
1	0.99	0.96	0.98	894
Accuracy			0.97	1662
Macro Avg	0.97	0.98	0.97	1662
Weighted Avg	0.98	0.97	0.97	1662

Sumber : Hasil Penelitian (2025)

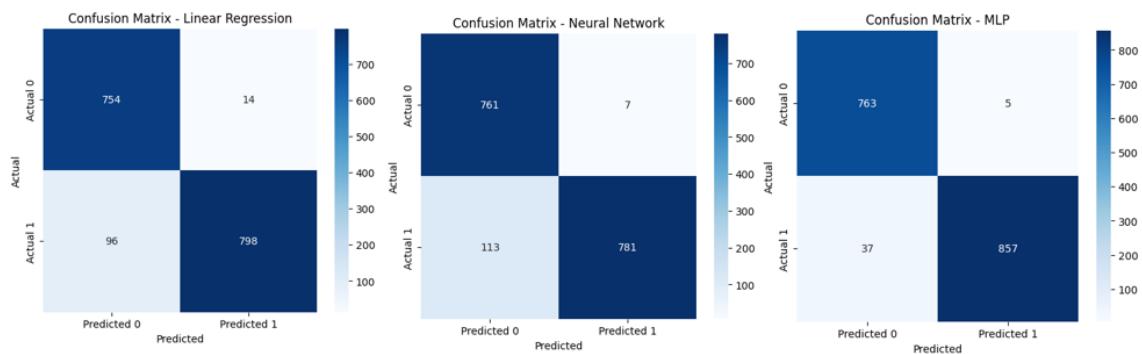
Tabel 3 hasil evaluasi model MLP berdasarkan metrik *Precision*, *Recall*, *F1-Score*, dan *Support* untuk dua kelas (0 dan 1). Model MLP menunjukkan *Precision* yang sangat tinggi untuk kedua kelas, dengan nilai 0.99 pada kelas 1 dan 0.95 pada kelas 0. *Recall* juga sangat baik, dengan nilai 0.99 untuk kelas 0 dan 0.96 untuk kelas 1, yang menunjukkan kemampuan model untuk mendekripsi data positif dengan sangat baik. *F1-Score* untuk kedua kelas adalah 0.97, yang menunjukkan keseimbangan antara *Precision* dan *Recall*. Model ini memiliki *Accuracy* sebesar 0.97, dengan *Macro Avg* dan *Weighted Avg* masing-masing 0.97 dan 0.98, yang menunjukkan performa yang sangat baik dan konsisten di seluruh kelas. Secara keseluruhan, model MLP memberikan kinerja terbaik dibandingkan dengan model lainnya, dengan akurasi yang tinggi dan keseimbangan yang baik dalam menangani kedua kelas.

Tabel 4 Hasil Perbandingan Model

Model	Precision	Recall	F1-Score	Support	MSE	R-squared
Linear Regression	0.93	0.93	0.93	1662	11.34	0.83
Neural Network	0.93	0.92	0.92	1662	5.41	0.92
MLP	0.97	0.97	0.97	1662	1.79	0.97

Sumber : Hasil Penelitian (2025)

Tabel 4 perbandingan hasil dari tiga model *Linear Regression*, *Neural Network*, dan MLP berdasarkan metrik *Precision*, *Recall*, *F1-Score*, *MSE*, dan *R-squared*. *Linear Regression* menunjukkan hasil yang baik dengan *Precision*, *Recall*, dan *F1-Score* sebesar 0.93, namun memiliki *MSE* yang tinggi (11.34) dan *R-squared* rendah (0.83). *Neural Network* memiliki *Precision* dan *Recall* masing-masing 0.93 dan 0.92, serta *R-squared* 0.92. MLP menunjukkan kinerja terbaik dengan *Precision*, *Recall*, dan *F1-Score* sebesar 0.97, serta *MSE* yang rendah (1.79) dan *R-squared* tinggi (0.97). Secara keseluruhan, MLP memberikan hasil terbaik di semua metrik.



Sumber : Hasil Penelitian (2025)

Gambar 12 Confusion Matrix

Gambar 12 confusion matrix untuk tiga model *Linear Regression*, *Neural Network*, dan MLP. Setiap matriks menggambarkan jumlah prediksi yang benar dan salah untuk dua kelas (0 dan 1), dengan angka di diagonal utama menunjukkan prediksi yang benar dan angka di luar diagonal menunjukkan kesalahan prediksi. Model *Linear Regression* menunjukkan beberapa kesalahan pada kelas 1 (14 salah prediksi) dan kelas 0 (96 salah prediksi). *Neural Network* menunjukkan prediksi yang lebih akurat dengan hanya 7 kesalahan pada kelas 1 dan 113 kesalahan pada kelas 0. MLP memberikan prediksi terbaik dengan hanya 5 kesalahan pada kelas 1 dan 37 kesalahan pada kelas 0. Secara keseluruhan, MLP menunjukkan performa terbaik dengan kesalahan yang paling sedikit.

4. KESIMPULAN DAN SARAN

Penelitian ini mengembangkan dan membandingkan tiga model *machine learning*, yaitu *Regresi Linier*, *Neural Network*, dan MLP, untuk memprediksi kekuatan beton. Hasil penelitian menunjukkan bahwa model MLP memberikan kinerja terbaik, dengan *Precision*, *Recall*, dan *F1-Score* yang sangat tinggi, serta *MSE* yang rendah dan *R-squared* mencapai 0.97, yang mengindikasikan bahwa MLP lebih efektif dalam menangani data yang kompleks dan memberikan prediksi yang lebih akurat dibandingkan dengan model lainnya. Model *Neural Network* dan *Regresi Linier* juga menunjukkan hasil yang baik, dengan *R-squared* masing-masing sebesar 0.92 dan 0.83, meskipun akurasi prediksi MLP jauh lebih tinggi. Penggunaan MLP terbukti memberikan hasil prediksi yang lebih presisi, mengurangi kesalahan prediksi secara signifikan, dan mampu menjelaskan sebagian besar variabilitas data kekuatan beton. Dengan demikian, MLP memiliki potensi besar untuk diterapkan dalam industri konstruksi untuk meningkatkan efisiensi dan akurasi prediksi kekuatan beton, yang selama ini masih bergantung pada uji laboratorium yang mahal dan memakan waktu. Pengembangan metode prediksi material dalam bidang konstruksi dapat mempercepat proses desain dan pengujian material beton, serta membantu para profesional konstruksi dalam membuat keputusan yang lebih tepat dan efisien. Di masa depan, penelitian ini

membuka peluang untuk pengembangan lebih lanjut dengan menggunakan dataset yang lebih besar dan penerapan teknik *machine learning* yang lebih kompleks guna meningkatkan akurasi prediksi.

DAFTAR PUSTAKA

- [1] N. D. Hoang and Q. L. Nguyen, “Compressive strength estimation of rice husk ash-blended high-strength concrete using diffGrad-optimized deep learning approach,” *Multiscale Multidiscip. Model. Exp. Des.*, vol. 7, no. 3, 2024, doi: 10.1007/s41939-023-00315-0.
- [2] V. Rathakrishnan, S. Bt. Beddu, and A. N. Ahmed, “Predicting compressive strength of high-performance concrete with high volume ground granulated blast-furnace slag replacement using boosting machine learning algorithms,” *Sci. Rep.*, vol. 12, no. 1, 2022, doi: 10.1038/s41598-022-12890-2.
- [3] J. S. Chou, S. Tjandrakusuma, and C. Y. Liu, “Jellyfish Search-Optimized Deep Learning for Compressive Strength Prediction in Images of Ready-Mixed Concrete,” *Comput. Intell. Neurosci.*, vol. 2022, 2022, doi: 10.1155/2022/9541115.
- [4] A. Tiwari, A. K. Gupta, and T. Gupta, “A robust approach to shear strength prediction of reinforced concrete deep beams using ensemble learning with SHAP interpretability,” *Soft Comput.*, vol. 28, no. 7–8, 2024, doi: 10.1007/s00500-023-09495-w.
- [5] M. Shahrokhishahraki, M. Malekpour, S. Mirvalad, and G. Faraone, “Machine learning predictions for optimal cement content in sustainable concrete constructions,” *J. Build. Eng.*, vol. 82, 2024, doi: 10.1016/j.jobe.2023.108160.
- [6] R. Alyousef *et al.*, “Forecasting the strength characteristics of concrete incorporating waste foundry sand using advance machine algorithms including deep learning,” *Case Stud. Constr. Mater.*, vol. 19, 2023, doi: 10.1016/j.cscm.2023.e02459.
- [7] H. Tanyildizi, A. Marani, K. Türk, and M. L. Nehdi, “Hybrid deep learning model for concrete incorporating microencapsulated phase change materials,” *Constr. Build. Mater.*, vol. 319, 2022, doi: 10.1016/j.conbuildmat.2021.126146.
- [8] D. A. Joshi, R. Menon, R. K. Jain, and A. V. Kulkarni, “Deep learning based concrete compressive strength prediction model with hybrid meta-heuristic approach,” *Expert Syst. Appl.*, vol. 233, 2023, doi: 10.1016/j.eswa.2023.120925.
- [9] A. T. Huynh *et al.*, “A machine learning-assisted numerical predictor for compressive strength of geopolymers concrete based on experimental data and sensitivity analysis,” *Appl. Sci.*, vol. 10, no. 21, 2020, doi: 10.3390/app10217726.
- [10] M. Hassani Niaki, M. Ghorbanzadeh Ahangari, and M. Pashaian, “A material-independent deep learning model to predict the tensile strength of polymer concrete,” *Compos. Commun.*, vol. 36, 2022, doi: 10.1016/j.coco.2022.101400.
- [11] N. Islam, A. Kashem, P. Das, M. N. Ali, and S. Paul, “Correction: Prediction of high-performance concrete compressive strength using deep learning techniques,” *Asian J. Civ. Eng.*, vol. 25, no. 1, 2024, doi: 10.1007/s42107-023-00814-y.
- [12] X. Liao, Q. Yan, H. Zhong, Y. Zhang, and C. Zhang, “Integrating PZT-enabled active sensing with deep learning techniques for automatic monitoring and assessment of early-age concrete strength,” *Meas. J. Int. Meas. Confed.*, vol. 211, 2023, doi: 10.1016/j.measurement.2023.112657.
- [13] X. Fang *et al.*, “Influence of mesoscopic pore characteristics on the splitting-tensile strength of cellular concrete through deep-learning based image segmentation,” *Constr. Build. Mater.*, vol. 315, 2022, doi: 10.1016/j.conbuildmat.2021.125335.
- [14] W. Wang, P. Shi, L. Deng, H. Chu, and X. Kong, “Residual strength evaluation of corroded

- textile-reinforced concrete by the deep learning-based method," *Materials (Basel)*., vol. 13, no. 14, 2020, doi: 10.3390/ma13143226.
- [15] H. Chen, J. Yang, and X. Chen, "A convolution-based deep learning approach for estimating compressive strength of fiber reinforced concrete at elevated temperatures," *Constr. Build. Mater.*, vol. 313, 2021, doi: 10.1016/j.conbuildmat.2021.125437.
- [16] Y. A. Nanehkaran *et al.*, "Deep learning method for compressive strength prediction for lightweight concrete," *Comput. Concr.*, vol. 32, no. 3, 2023, doi: 10.12989/cac.2023.32.3.327.
- [17] M. S. Mahmood *et al.*, "Enhancing compressive strength prediction in self-compacting concrete using machine learning and deep learning techniques with incorporation of rice husk ash and marble powder," *Case Stud. Constr. Mater.*, vol. 19, 2023, doi: 10.1016/j.cscm.2023.e02557.
- [18] M. M. Woldeamanuel, T. Kim, S. Cho, and H. K. Kim, "Estimation of concrete strength using thermography integrated with deep-learning-based image segmentation: Case studies and economic analysis," *Expert Syst. Appl.*, vol. 213, 2023, doi: 10.1016/j.eswa.2022.119249.
- [19] O. R. Abuodeh, J. A. Abdalla, and R. A. Hawileh, "Assessment of compressive strength of Ultra-high Performance Concrete using deep machine learning techniques," *Appl. Soft Comput. J.*, vol. 95, 2020, doi: 10.1016/j.asoc.2020.106552.
- [20] M. Verma, "Prediction of compressive strength of geopolymer concrete using random forest machine and deep learning," *Asian J. Civ. Eng.*, vol. 24, no. 7, 2023, doi: 10.1007/s42107-023-00670-w.
- [21] S. D. Latif, "Concrete compressive strength prediction modeling utilizing deep learning long short-term memory algorithm for a sustainable environment," *Environ. Sci. Pollut. Res.*, vol. 28, no. 23, 2021, doi: 10.1007/s11356-021-12877-y.
- [22] P. Weng, J. Xie, and Y. Zou, "Compressive strength prediction of admixed HPC concrete by hybrid deep learning approaches," *J. Intell. Fuzzy Syst.*, vol. 44, no. 5, 2023, doi: 10.3233/JIFS-221714.
- [23] L. Yang, X. An, and S. Du, "Estimating workability of concrete with different strength grades based on deep learning," *Meas. J. Int. Meas. Confed.*, vol. 186, 2021, doi: 10.1016/j.measurement.2021.110073.
- [24] Z. Zeng *et al.*, "Accurate prediction of concrete compressive strength based on explainable features using deep learning," *Constr. Build. Mater.*, vol. 329, 2022, doi: 10.1016/j.conbuildmat.2022.127082.
- [25] G. A. Lyngdoh, M. Zaki, N. M. A. Krishnan, and S. Das, "Prediction of concrete strengths enabled by missing data imputation and interpretable machine learning," *Cem. Concr. Compos.*, vol. 128, 2022, doi: 10.1016/j.cemconcomp.2022.104414.
- [26] S. Selcuk and P. Tang, "A metaheuristic-guided machine learning approach for concrete strength prediction with high mix design variability using ultrasonic pulse velocity data," *Dev. Built Environ.*, vol. 15, 2023, doi: 10.1016/j.dibe.2023.100220.
- [27] M. Verma, K. Uperti, P. Dadhich, S. Ghosh, V. Khatri, and P. Singh, "Prediction of Compressive Strength of Green Concrete by Artificial Neural Network," in *Communications in Computer and Information Science*, 2023. doi: 10.1007/978-3-031-25088-0_55.
- [28] J. A. Guzmán-Torres, F. J. Domínguez-Mota, E. M. Alonso-Guzmán, G. Tinoco-Guerrero, and W. Martínez-Molina, "ConcreteXAI: A multivariate dataset for concrete strength prediction via deep-learning-based methods," *Data Br.*, vol. 53, 2024, doi: 10.1016/j.dib.2024.110218.