

- Word Count: 2425

Plagiarism Percentage

0%

sources:

There are no matching sources for this report.

paper text:

PREDIKSI KUAT TEKAN BETON DENGAN MENGGUNAKAN METODE ARTIFICIAL INTELLIGENCE

Doddy Prayogo^{1*} 1) Program Studi Teknik Sipil, Universitas Kristen Petra prayogo@petra.ac.id ABSTRAK

Metode yang akurat dalam memprediksi kuat tekan beton dapat memberikan keuntungan yang signifikan terhadap industri material konstruksi. Namun, metode-metode tradisional yang ada sekarang ini memiliki banyak kekurangan, diantaranya biaya eksperimen yang mahal dan ketidakmampuan untuk menjabarkan hubungan antara komponen-komponen campuran beton dengan kuat tekan yang dihasilkan. Oleh sebab itu, studi ini memperkenalkan metode-metode kecerdasan buatan yang mampu memetakan hubungan input-output yang kompleks dalam campuran beton dengan tingkat akurasi yang tinggi. Dua buah metode artificial intelligence (AI), diantaranya artificial neural network (ANN), dan support vector machine (SVM) digunakan dalam studi ini. Total 1030 data historis dari data tes kuat tekan beton disediakan untuk mendemonstrasikan penggunaan model prediksi AI. Hasil simulasi menunjukkan bahwa metode-metode kecerdasan buatan ini mampu menghasilkan model prediksi dengan akurasi yang baik. Kata Kunci: artificial intelligence, kuat tekan beton, artificial neural network, support vector machine

1. PENDAHULUAN

Material beton sudah menjadi material yang umum digunakan dalam industri konstruksi beberapa tahun terakhir ini dikarenakan telah terbukti dapat menunjukkan karakteristik kekuatan tinggi yang stabil. Selain empat bahan dasar beton konvensional; yaitu semen, agregat kasar dan halus, dan air; material penyusun semen lainnya sudah mulai digunakan, di antara lain fly ash, blast furnace slag, dan campuran kimia seperti superplasticizer (Yeh, 1998). Penggunaan material penyusun semen tambahan juga menghasilkan manfaat ekonomi karena semen portland adalah komponen paling mahal dari campuran beton. Di sisi lain, penggunaan zat aditif pada beton semakin populer karena dapat meningkatkan workability, durability, dan bahkan kekuatan. Tambahan-tambahan baru pada campuran beton ini memperkenalkan dimensi baru pada pemodelan kekuatan tekan beton yang berakibat pada bertambahnya tingkat kerumitan. Namun, metode pemodelan tradisional yang biasanya digunakan untuk memprediksi perilaku beton menjadi kurang mampu untuk menghasilkan hasil prediksi yang akurat. Umumnya, tes kekuatan biasanya dilakukan 7–28 hari setelah proses penuangan beton. Masa tunggu 28 hari yang diperlukan untuk melakukan tes seperti itu dapat menyebabkan proses konstruksi tahap selanjutnya menjadi sedikit tertunda (Prayogo, 2018; Prayogo et al., 2017). Namun, mengabaikan pengujian akan membatasi kontrol kualitas pada skala konstruksi yang besar dan rumit. Oleh karena itu, prediksi kekuatan beton yang cepat dan dapat diandalkan sangat penting untuk kontrol kualitas, bahkan pada tahapan desain awal (Chou et al., 2011). Jika penyesuaian proporsi campuran dapat dilakukan dengan cepat bilamana kekuatan beton tidak memenuhi spesifikasi, akan terjadi penghematan waktu dan biaya konstruksi. Prediksi awal kekuatan beton sangat penting untuk memperkirakan waktu yang diperlukan untuk pembukaan bekisting beton, penjadwalan proyek, dan kontrol kualitas (Chou et al., 2011). Karena hubungan antara komponen dan sifat beton sangatlah nonlinear, pemodelan dengan menggunakan pendekatan matematis menjadi rumit. Persamaan empiris yang disajikan

dalam standard code saat ini untuk memperkirakan kekuatan tekan didasarkan pada pengujian beton tanpa material penyusun semen tambahan. Memahami hubungan antara komposisi dan kekuatan beton sangat penting untuk mengoptimalkan campuran beton (Cheng, Firdausi, et al., 2014; Yeh, 1999). Banyak penelitian dilakukan dengan cara menggunakan uji eksperimen yang biasanya memakan waktu dan biaya yang besar. Untuk itu, dibutuhkan sistem pemodelan baru yang tidak tergantung pada eksperimen namun tetap dapat memprediksi kekuatan beton dengan tingkat akurasi yang tinggi. Akhir-akhir ini, metode artificial intelligence (AI) semakin banyak dipakai dalam penyelesaian problem klasifikasi dan regresi karena terbukti lebih akurat daripada metode konvensional (Cheng & Prayogo, 2016; Cheng et al., 2016; Cheng et al., 2015; Hoang et al., 2018; Prayogo & Susanto, 2018; Tran & Hoang, 2016). Penelitian ini mengembangkan teknik AI untuk memprediksi secara akurat kekuatan tekan beton dari berbagai macam komponen. Data eksperimen diambil dari machine learning repository dari University of California, Irvine yang dikumpulkan oleh Yeh (1998) untuk memprediksi kekuatan tekan di HPC. Pemodelan AI dilakukan di IBM SPSS Modeler 18.1 dengan menggunakan dua teknik prediktif, yaitu artificial neural network (ANN) dan support vector machine (SVM).

2. METODE ARTIFICIAL INTELLIGENCE

2.1. Artificial Neural Network ANN

adalah model komputasi yang mencoba mensimulasikan struktur dan aspek fungsional jaringan saraf biologis. Berbagai aplikasi ANN dapat dikategorikan sebagai model klasifikasi maupun model regresi. Penggunaan ANN khusus untuk memprediksi kekuatan tekan beton telah dipelajari secara intensif (Yeh, 1999; Yeh, 1998). Para peneliti juga mengeksplorasi penggunaan ANN untuk membangun model kekuatan tekan beton yang lebih akurat daripada model regresi. Model ANN yang paling digunakan adalah model multilayer perceptron (MLP). Dalam model MLP, input layer berisi satu set input nodes yang bersifat sensorik, satu atau lebih hidden layer yang berfungsi untuk melakukan komputasi, dan output layer berisi satu node komputasi yang mewakili kuat tekan beton. Algoritma pembelajaran yang paling banyak digunakan dan efektif untuk melatih model MLP adalah algoritma back-propagation (BP). Proses aktivasi dari setiap neuron dalam dapat dilihat pada Persamaan (1) dan (2).
$$z_k = \sum_j w_{jk} a_j + b_k \quad (1)$$

$$a_k = \max(0, z_k) \quad (2)$$
 di mana a_k adalah aktivasi dari neuron ke k , j merupakan set dari neuron-neuron di layer sebelumnya. w_{jk} adalah bobot dari koneksi antara neuron k dan neuron j , b_k adalah output dari neuron j , dan \max melambungkan output yang biasanya dihitung dalam fungsi transfer sigmoid maupun logistik. Ilustrasi dari struktur ANN dapat dilihat melalui Gambar 1. Gambar 1. Ilustrasi struktur ANN

2.2. Support Vector Machine SVM

pertama kali diperkenalkan oleh Vapnik (1995). SVM telah digunakan dalam banyak aplikasi teknik sipil dan dalam beberapa tahun terakhir mulai sering digunakan untuk memprediksi kuat tekan beton (Cheng, Prayogo, et al., 2014; Pham et al., 2015; Prayogo et al., 2018). Dalam penelitian ini, support vector regression (ϵ -SVR), yang merupakan variasi dari SVM, digunakan untuk membangun model input-output dari beton. SVM menggunakan sebuah fungsi objektif yang memungkinkan proses estimasi fungsi terjadi seperti yang diilustrasikan pada Gambar 2. Ketika didapati space yang sangat nonlinier terjadi, kernel radial-based function (RBF) dipilih sebagai fungsi kernel di dalam SVM dikarenakan dapat memberikan hasil yang lebih baik daripada kernel-kernel yang lain. X2 Optimal hyperplane Support vectors Support vectors class 1 class 2 X1 Gambar 2. Ilustrasi pemisahan hyperplane dan penentuan support vector oleh SVM Model berikut mendasari hubungan fungsional antara satu atau lebih variabel independen dengan variabel respon: $y(x) = w^T \phi(x) + b \quad (3)$ di mana $x \in \mathbb{R}^n, y \in \mathbb{R}$, dan $\phi(x) \in \mathbb{R}^n$ adalah proses pemetaan ke feature space yang berdimensi lebih tinggi. Dalam SVM untuk analisa regresi, suatu kumpulan data $\{x_k, y_k\}_{k=1}^N$, fungsi objektifnya dapat dirumuskan sebagai berikut:
$$\min_{w, e} \sum_{k=1}^N (w^T x_k + b - y_k + e_k) \quad (4)$$
 s.t. $y_k = w^T \phi(x_k) + b + e_k, k=1, \dots, N \quad (5)$ di mana $e_k \in \mathbb{R}$ adalah variabel error; c menunjukkan konstanta regularisasi.

3. PEMODELAN EKSPERIMEN

3.1. Deskripsi Data Eksperimen

Data eksperimen diperoleh dari machine learning repository dari University of California, Irvine (UCI) yang dikumpulkan oleh Yeh (1998). Sebanyak 1030 sampel beton yang dievaluasi dari berbagai laboratorium penelitian universitas digunakan untuk menguji model prediksi dari masing-masing metode AI. Semua tes dilakukan pada spesimen beton 15 cm silinder yang dibuat dengan menggunakan prosedur standar. Tabel 1

menunjukkan set data eksperimen dari sembilan variabel HPC yang digunakan dalam penelitian ini. Tabel 1. Variabel yang mempengaruhi kuat tekan beton beserta statistik deskriptifnya Variabel Min Rata-rata Max Standar deviasi X1: Semen (kg/m³) 102.0 281.17 540.0 104.51 X2: Blast-furnace slag (kg/m³) 11.0 107.28 359.4 61.88 X3: Fly ash (kg/m³) 24.5 83.86 200.1 39.99 X4: Air (kg/m³) 121.8 181.57 247.0 24.35 X5: SP (kg/m³) 1.7 8.49 32.2 4.04 X6: Agregat kasar (kg/m³) 801.0 972.92 1,145.0 77.75 X7: Agregat halus (kg/m³) 594.0 773.58 992.6 80.18 X8: Waktu tes (hari) 1.0 45.66 365.0 63.17 Y: Kuat tekan beton (MPa) 2.3 35.82 82.6 16.71

3.2. Indikator Akurasi dari Model Prediksi AI Tabel 2 menunjukkan model pengukuran kinerja yang digunakan untuk mengestimasi keakuratan dari masing-masing metode prediktif. Model akurasi ini dihitung berdasarkan seberapa akuratnya hubungan antara data aktual dan hasil prediksi dari variabel output. Empat model pengukuran kinerja ini diantaranya root mean square error (RMSE), mean absolute error (MAE), mean absolute percentage error (MAPE) dan coefficient of correlation (R). RMSE mengukur simpangan rata-rata dari masing-masing titik data aktual dan hasil prediksi. MAE menghitung rata-rata kesalahan dengan menggunakan selisih absolut dari data aktual dan hasil prediksi. Kekuatan hubungan linier antara dua variabel diukur dengan R. Meskipun mirip dengan MAE yang menggunakan selisih absolut pada perhitungan akurasi, MAPE memiliki kelebihan dimana tidak terpengaruh oleh unit dan ukuran nilai yang diprediksi dan aktual, sehingga dapat lebih efisien dalam menentukan perbedaan relatif antara model. Di sini, nilai $R = -1$ mewakili korelasi negatif sempurna, sedangkan nilai $R = 1$ menunjukkan korelasi positif yang sempurna. Hasil model terbaik ditunjukkan oleh nilai R tertinggi, dan nilai RMSE, MAE, dan MAPE yang terendah.

Tabel 2. Indikator akurasi model prediksi

Indikator akurasi model Formula matematis

$$R = \frac{n \sum (y - \hat{y})^2 - (\sum (y - \hat{y}))^2}{\sqrt{[n \sum (y - \hat{y})^2 - (\sum (y - \hat{y}))^2] [n \sum (\hat{y} - \bar{y})^2 - (\sum (\hat{y} - \bar{y}))^2]}}$$

$$RMSE = \sqrt{\frac{1}{n} \sum (y - \hat{y})^2}$$

$$MAPE = \frac{1}{n} \sum \frac{|y - \hat{y}|}{y}$$

$$MAE = \frac{1}{n} \sum |y - \hat{y}|$$

dimana y adalah output aktual dan \hat{y} adalah output hasil prediksi

3.3. Pembentukan diagram alir model prediksi AI Model AI dari software IBM SPSS Modeler 18.1 digunakan untuk membentuk model prediksi yang akurat. Meskipun platform ini relatif mudah digunakan untuk penggunaan metode-metode AI, namun tetap dibutuhkan diagram alir yang tepat untuk membentuk model prediksi yang akurat. Gambar 3 menjelaskan diagram alir untuk membangun model prediksi AI tersebut. Gambar 3. Diagram alir pembentukan model prediksi AI Adapun kelima langkah daripada pembentukan model AI ini dijabarkan sebagai berikut.

1. Data input: langkah ini merupakan langkah awal dimana koleksi data akan diambil untuk tahap selanjutnya.
2. Training dan testing: dari data input, akan dibagi menjadi 2 grup data yaitu data untuk training dan data untuk testing. Training digunakan untuk membuat model prediksi yang pas dengan data sedangkan testing digunakan untuk menguji model prediksi yang dibangun. Dalam studi ini, 70% dari data akan digunakan untuk training, dan 30% dari data akan digunakan untuk testing.
3. Proses pembelajaran model prediksi AI dengan data training.
4. Proses pengujian model prediksi AI dengan data testing.
5. Hasil prediksi: keempat indikator akurasi akan digunakan untuk mengukur performa dari hasil prediksi yang didapatkan setiap model.

4. HASIL DAN PEMBAHASAN Penelitian ini membandingkan kemampuan dua metode AI, yaitu ANN dan SVM dalam memprediksi kuat tekan beton dari 1030 data sampel beton. Dari 1030 data tersebut, 723 data digunakan untuk training, dan 307 data digunakan untuk testing. ANN dan SVM menggunakan parameter default dari IBM SPSS Modeler 18.1. Seperti yang telah diuraikan sebelumnya, R, RMSE, MAPE, dan MAE digunakan untuk mengetahui seberapa akurat dari masing-masing metode prediksi. Hasil analisa dari keempat indikator terhadap masing-masing metode terhadap data testing dapat dilihat pada Tabel 3.

Tabel 3. Hasil penilaian performa model prediksi terhadap data testing

Metode	R	RMSE (MPa)	MAPE (%)	MAE (MPa)
ANN	0.909	7.176	19.93	5.550
SVM	0.779	10.914	32.59	8.687

Dari Tabel 3, terlihat bahwa ANN berhasil mengungguli SVM di keempat buah indikator akurasi. ANN mendapatkan R sebesar 0.909, lebih tinggi daripada SVM yang hanya mendapatkan R sebesar 0.799. Sementara itu, ANN menghasilkan tingkat error yang lebih rendah dibandingkan SVM, dimana RMSE, MAE, dan MAPE yang dihasilkan jauh lebih rendah daripada SVM. ANN mendapatkan 7.176 MPa, 19.93%, 5.550 MPa untuk RMSE, MAPE, dan MAE, secara berurutan. Sementara itu SVM hanya bisa menghasilkan

10.914 MPa, 32.59%, 8.667 MPa untuk RMSE, MAPE, dan MAE, secara berurutan. Lebih lanjut lagi Gambar 4 dan 5 menunjukkan hasil prediksi dari ANN dan SVM. Terlihat pada gambar tersebut, apabila hasil prediksi semakin mendekati garis diagonal, maka hasil prediksi dapat dikatakan akurat. Dari Gambar 4 dan 5, dapat disimpulkan secara visual bahwa hasil prediksi ANN lebih akurat karena hasil prediksi dari masing-masing titik lebih mendekati garis diagonal.

80 70 Kuat tekan beton prediksi (MPa) 60 50 40 30 20
10 0 0 20 40 60 80 100 Kuat tekan beton aktual (MPa) Gambar 4. Perbandingan hasil prediksi dan aktual pada data testing untuk metode ANN

80 70 Kuat tekan beton prediksi (MPa) 60 50 40 30 20 10 0 0 20 40 60
80 100 Kuat tekan beton aktual (MPa) Gambar 5. Perbandingan hasil prediksi dan aktual pada data testing untuk metode SVM

5. KESIMPULAN

Penelitian ini menyajikan studi perbandingan antara dua metode AI, yaitu ANN dan SVM, dalam memprediksi kuat tekan beton berdasarkan sejumlah data sampel beton. Sejumlah 1030 data sampel digunakan untuk membuat model prediksi sekaligus untuk menguji keakuratan dari model prediksi yang dibentuk. Empat buah indikator akurasi digunakan dalam mengevaluasi performa dari masing-masing metode, antara lain R, RMSE, MAPE, dan MAE. Eksperimen dilakukan dengan menggunakan software IBM SPSS Modeler 18.1. Dari hasil eksperimen didapatkan bahwa ANN adalah yang terbaik diantara kedua metode karena dapat memberikan performa yang paling optimal dari keempat indikator. Penelitian ini berhasil membuktikan bahwa metode-metode AI mampu memprediksi kuat tekan beton tanpa melakukan eksperimen di laboratorium dengan tingkat akurasi yang tinggi.

6. DAFTAR PUSTAKA

Cheng, M.-Y., Firdausi, P. M., & Prayogo, D. (2014). High-performance concrete compressive strength prediction using Genetic Weighted Pyramid Operation Tree (GW POT). *Engineering Applications of Artificial Intelligence*, 29, 104-113.

Cheng, M.-Y., & Prayogo, D. (2016). Modeling the permanent deformation behavior of asphalt mixtures using a novel hybrid computational intelligence. Paper presented at the ISARC 2016 - 33rd International Symposium on Automation and Robotics in Construction.

Cheng, M.-Y., Prayogo, D., Ju, Y.-H., Wu, Y.-W., & Sutanto, S. (2016). Optimizing mixture properties of biodiesel production using genetic algorithm-based evolutionary support vector machine. *International Journal of Green Energy*, 13(15), 1599-1607.

Cheng, M.-Y., Prayogo, D., & Wu, Y.-W. (2014). Novel Genetic Algorithm-Based Evolutionary Support Vector Machine for Optimizing High-Performance Concrete Mixture. *Journal of Computing in Civil Engineering*, 28(4), 06014003.

Cheng, M.-Y., Wibowo, D. K., Prayogo, D., & Roy, A. F. V. (2015). Predicting productivity loss caused by change orders using the evolutionary fuzzy support vector machine inference model. *Journal of Civil Engineering and Management*, 21(7), 881-892.

Chou, J.-S., Chiu, C.-K., Farfoura, M., & Al-Taharwa, I. (2011). Optimizing the Prediction Accuracy of Concrete Compressive Strength Based on a Comparison of Data-Mining Techniques. *Journal of Computing in Civil Engineering*, 25(3), 242-253.

Hoang, N.-D., Liao, K.-W., & Tran, X.-L. (2018). Estimation of scour depth at bridges with complex pier foundations using support vector regression integrated with feature selection. *Journal of Civil Structural Health Monitoring*, 8(3), 431-442.

Pham, A.-D., Hoang, N.-D., & Nguyen, Q.-T. (2015). Predicting Compressive Strength of High-Performance Concrete Using Metaheuristic-Optimized Least Squares Support Vector Regression. *Journal of Computing in Civil Engineering*, 06015002.

Prayogo, D. (2018). Metaheuristic-Based Machine Learning System for Prediction of Compressive Strength based on Concrete Mixture Properties and Early-Age Strength Test Results. *Civil Engineering Dimension*, 20(1), 21-29.

Prayogo, D., Cheng, M. Y., Widjaja, J., Ongkowijoyo, H., & Prayogo, H. (2017). Prediction of concrete compressive strength from early age test result using an advanced metaheuristic-based machine learning technique. Paper presented at the ISARC 2017 - Proceedings of the 34th International Symposium on Automation and Robotics in Construction.

Prayogo, D., & Susanto, Y. T. T. (2018). Optimizing the Prediction Accuracy of Friction Capacity of Driven Piles in Cohesive Soil Using a Novel Self-Tuning Least Squares Support Vector Machine. *Advances in Civil Engineering*, 2018.

Prayogo, D., Wong, F. T., & Tjandra, D. (2018). Prediction of High-Performance Concrete Strength Using a Hybrid Artificial Intelligence Approach. *MATEC Web of Conferences*, 203, 06006.

Tran, T.-H., & Hoang, N.-D. (2016). Predicting

