

PENGGUNAAN ARTIFICIAL NEURAL NETWORK UNTUK MEMPREDIKSI LOAD-SETTLEMENT CURVE PADA FONDASI TIANG

Raden Harya Dananjaya¹, Sutrisno², Damian Paska Santyo Brahman¹

¹Program Studi Teknik Sipil, Fakultas Teknik, Universitas Sebelas Maret

²Program Studi Teknik Elektro, Fakultas Teknik, Universitas Sebelas Maret

Jl. Ir. Sutami 36A, Kentingan, Surakarta 57126, Telp. (0271) 634524, Fax 662118

Email: dananjaya.harya@staff.uns.ac.id

Abstract

The different soil conditions in a project make it difficult to plan foundations because they have to go through a series of calculations and planning processes conventionally or through simulations. When doing the calculations, data on soil conditions is needed, the value of which is still based on assumptions. Based on that, we need a method that can predict the foundation's settlement based on the actual conditions. In recent years, artificial neural networks (ANN) have been applied to many geotechnical problems. In pile foundation design, accurate pile settlement prediction is required to ensure proper structural performance. This study aims to build an ANN model to predict pile settlement based on cone penetration test (CPT) test data. The data obtained from the literature was used to develop the model. In addition, this study discusses the best parameters to get the optimal model. Finally, this study compares the predictions obtained by ANN with static load tests in the field using a validation method using *k*-fold cross-validation. After doing the training and testing, the coefficient of determination test results were 0.77 and RMSE 174 kN. The result of the cross-validation coefficient of determination is 0.68.

Keywords: ANN, CPT, *k*-folds cross-validation, load-settlement curve

Abstrak

Kondisi tanah yang berbeda-beda pada suatu proyek menyebabkan sulitnya merencanakan fondasi karena harus melalui serangkaian proses perhitungan dan perencanaan secara konvensional atau melalui simulasi. Ketika melakukan perhitungan dibutuhkan data-data kondisi tanah, yang mana nilainya masih berdasarkan pada asumsi. Berdasarkan hal itu diperlukan metode yang mampu memprediksi penurunan fondasi dengan kondisi yang sebenarnya. Dalam beberapa tahun terakhir *Artificial Neural Network (ANN)* telah dikembangkan dalam permasalahan teknik. Berhubungan dengan desain fondasi tiang, prediksi penurunan tiang yang akurat diperlukan untuk memastikan kinerja struktural yang sesuai. Pada penelitian ini bertujuan untuk membangun model ANN untuk memprediksi penurunan tiang berdasarkan data uji sondir (CPT). Data yang diperoleh dari literatur, digunakan untuk mengembangkan model. Selain itu, dalam penelitian ini membahas parameter terbaik untuk mendapatkan model yang optimal. Akhirnya pada penelitian ini membandingkan prediksi yang diperoleh ANN dengan *static load test* di lapangan dengan metode validasi menggunakan *k*-fold cross validation. Setelah melakukan *training* dan *testing* didapatkan hasil uji koefisien determinasi sebesar 0,77 dan RMSE 174 kN. Hasil *cross validation* koefisien determinasi adalah 0,68.

Kata Kunci : ANN, CPT, *k*-folds cross validation, load-settlement curve

PENDAHULUAN

Perencanaan fondasi memerlukan ketelitian yang berhubungan dengan sifat dan karakteristik tanah. Fondasi memiliki tugas utama, yaitu memikul beban sampai batas aman yang telah ditentukan. Selain kekuatannya, penurunan fondasi akibat beban rencana juga dibatasi, apabila terjadi penurunan yang melebihi batas, maka perlu dikaji ulang desain dan perhitungan penurunannya (Luthfiani et al., 2017).

Penurunan fondasi membutuhkan banyak asumsi faktor-faktor yang mempengaruhinya. Metode konvensional untuk menghitung nilai penurunan fondasi yang ada saat ini masih menggunakan asumsi-asumsi. Banyaknya faktor-faktor yang mempengaruhi penurunan akan menyulitkan metode konvensional untuk melakukan penghitungan. Untuk mengatasi hal tersebut maka penulis menggunakan metode *artificial neural network*, yang dianggap mampu mengolah banyak faktor dan hasilnya yang juga lebih akurat.

Penelitian ini akan mengembangkan *script* yang berbasis kecerdasan buatan untuk memprediksi penurunan fondasi. Berbagai data historis dari berbagai proyek di seluruh dunia mulai dari data CPT, in-situ *load test* dan spesifikasi desain fondasi diolah dengan metode *Artificial Neural Network* dimanfaatkan sebagai data untuk memprediksi *load-settlement curve* suatu fondasi. Penelitian ini bertujuan untuk menghasilkan prediksi *load-settlement curve* fondasi yang mendekati hasil di lapangan daripada perhitungan secara konvensional karena data yang diolah adalah data uji langsung lapangan.

Cone Penetration Test (CPT)

Uji penetrasi kerucut statis adalah jenis uji penetrasi yang banyak digunakan untuk melakukan penyelidikan tanah (Eslami et al., 2020). Alasan CPT banyak digunakan, yaitu; CPT sederhana dan relatif ekonomis. Pengujian ini mampu mengambil data sepanjang kedalaman pengujian. Hasilnya disajikan dalam bentuk *bor log*. Dua pengukuran CPT yang umum adalah resistansi ujung kerucut, *qc*, dan *friction sleeve, fs*. Resistensi ujung kerucut adalah rasio gaya vertikal pada area proyeksi titik kerucut. *Friction sleeve* adalah tegangan geser yang bekerja akibat gesekan yang terjadi. Hasil uji penetrasi kerucut akan digunakan sebagai bahan untuk mengembangkan model prediksi.

Pile Load Test

Uji beban statis merupakan uji untuk memperoleh data *load-settlement curve* tiang pancang tertanam. Beban statis diaplikasikan menggunakan dongkrak hidrolis dan diukur dengan sel beban. Reaksi terhadap beban dongkrak didukung oleh kerangka baja yang dipasang pada susunan *H-pile* baja yang terletak 3 m dari tiang uji. Defleksi kepala tiang diukur terhadap balok referensi tetap menggunakan *dial gauges*. Pengukuran *telltale* (penanda) dilakukan dengan mengacu pada kepala tiang atau balok referensi menggunakan *dial gauge* (Bradshaw, 2006; Chen, dkk, 2020; Murli-dhar, dkk, 2020). Hasil dari uji beban statis akan digunakan sebagai bahan untuk mengembangkan model prediksi.

Artificial Neural Network (ANN)

Artificial neural networks adalah bentuk *artificial intelligence* yang mencoba meniru fungsi otak dan sistem saraf manusia (Shahin, 2016; Jong, dkk, 2021; Zhang, dkk, 2021). *ANN* merupakan struktur pemrosesan sederhana yang adaptif dan saling terhubung juga mampu melakukan komputasi untuk pemrosesan data. Model seperti ANN diperlukan karena sifatnya yang mampu mengolah data non-linear dengan hasil yang baik. Mengolah data dengan cepat karena sifatnya yang memproses secara paralel. ANN mampu membuat model secara general sehingga dapat diterapkan pada data yang tidak dipelajari (Basheer & Hajmeer, 2000; Aljarah, 2018).

Evaluasi Analisis Regresi

Analisis regresi merupakan bagian besar dari pembelajaran mesin yang diawasi (*supervised*). Model regresi mencoba menyesuaikan data dengan menggambar garis yang meminimalkan jarak antara titik pada garis yang sama dengan titik data sebenarnya. Semakin dekat nilainya dengan garis maka semakin baik sebuah model. Evaluasi model sangat penting dalam analisis data. Hal ini memberikan kemudahan untuk memahami dan menyajikan kinerja model. Banyak penelitian menggunakan *Mean Square Error (MSE)*, *Root Mean Square Error (RMSE)*, atau *Mean Absolute Error (MAE)* untuk mengevaluasi kinerja model dalam analisis regresi (Chicco et al., 2021).

Pada persamaan [1], [2], dan [3], X_i adalah nilai ke i yang diprediksi, dan variabel Y_i adalah nilai ke i yang sebenarnya. Metode regresi memprediksi variabel X_i untuk variabel Y_i yang sesuai dengan yang sebenarnya dari dataset. Selanjutnya dijelaskan macam-macam metode evaluasi regresi.

Koefisien determinasi (R^2) dapat diartikan sebagai proporsi variasi pada variabel dependen yang dapat diprediksi dari variabel independen. Koefisien determinasi dinyatakan dalam persamaan [1].

$$R^2 = 1 - \frac{\sum_{i=1}^m (X_i - Y_i)^2}{\sum_{i=1}^m (Y - Y_i)^2} \dots\dots\dots [1]$$

MSE dapat digunakan jika terdapat *outlier* yang perlu dideteksi. Hasil MSE menggambarkan rata-rata selisih antara nilai aktual dan prediksi yang dikuadratkan. Rumus MSE dinyatakan dalam persamaan [2].

$$MSE = \frac{1}{m} \sum_{i=1}^m (X_i - Y_i)^2 \dots\dots\dots [2]$$

RMSE merupakan jumlah kesalahan kuadrat, atau selisih antara nilai aktual dan nilai prediksi yang diberikan. Nilai RMSE dihitung dengan cara yang sama seperti MSE, namun RMSE melalui proses akar. Rumus RMSE dinyatakan dalam persamaan [3].

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (X_i - Y_i)^2} \dots\dots\dots [3]$$

METODE

Pengumpulan Data

Tahapan awal dalam penelitian ini dilakukan pengumpulan data yang akan digunakan selanjutnya dalam analisis. Data yang digunakan merupakan data sekunder berupa hasil uji *CPT*, *loading test*, dan spesifikasi dari fondasi yang berasal dari berbagai proyek konstruksi di seluruh dunia.

Penentuan Variabel Data

Variabel *input* yang digunakan berasal dari hasil uji tanah, berupa data *Cone Penetration Test (CPT)*, *in situ Loading test*, dan spesifikasi dari fondasi tiang yang ditinjau. Hasil *CPT* berupa tahanan ujung tiang ($q_{c_{tip}}$), tahanan gesek tiang ($q_{c_{shaft}}$). Hasil *loading test* didapatkan dari hasil pengujian lapangan, berupa *load-settlement curve*. Spesifikasi dari fondasi tiang yang digunakan sebagai data input terdiri dari panjang tiang tertanan (L), diameter (D), luas penampang (A), bentuk tiang, material bahan tiang, dan jenis tiang. Data geoteknik penurunan fondasi tiang yang telah didapat kemudian diolah, seluruh data digabungkan menjadi satu tabel yang terdiri dari kolom dan baris. Setiap kolom menyimpan variabel yang mempengaruhi penurunan fondasi tiang.

Pembagian Data

Data dibagi menjadi tiga bagian: *training*, *testing*, dan *validation*. Data *training* digunakan untuk menyesuaikan hubungan bobot, sedangkan data *validation* digunakan untuk mengukur kinerja dari model ANN dan memilih model ANN yang terbaik. Data *testing* digunakan untuk memperkirakan kinerja model ANN yang telah di *training*, sehingga dapat digunakan secara umum. Pada penelitian ini penulis menggunakan proporsi data *training*, dan *testing* dengan perbandingan 90:10, dengan data *validation* menggunakan metode *k-fold cross validation*. Nilai k pada penelitian ini bernilai 10 yang mana memanfaatkan data *training* berdasarkan jumlah grup yang telah ditentukan sebesar 10 lipatan atau 10% data *validation* yang berbeda-beda. Data yang penulis gunakan sebanyak 39 studi kasus fondasi tiang. Sehingga dalam proporsi pembagian data maka dapat dihasilkan jumlah data masing-masing. Data *training* sebanyak 31 studi kasus fondasi tiang, dan data *testing* sebanyak 4.

Training dan Testing Model ANN

Training atau proses belajar merupakan suatu proses optimasi bobot suatu hubungan. Metode yang umum digunakan untuk membangun kombinasi bobot optimal adalah *feed-forward neural networks*. Kemudian dilakukan tahap *testing*, yang mana data ini merupakan data diluar dari data *training*. Sehingga data *testing* tidak dipengaruhi oleh proses apa pun. Hal ini dimaksudkan agar hasil prediksi yang didapat benar-benar sesuai dengan model dan hasil *training* yang sebenarnya. Sehingga model ini mampu digunakan untuk penghitungan dengan data lainnya.

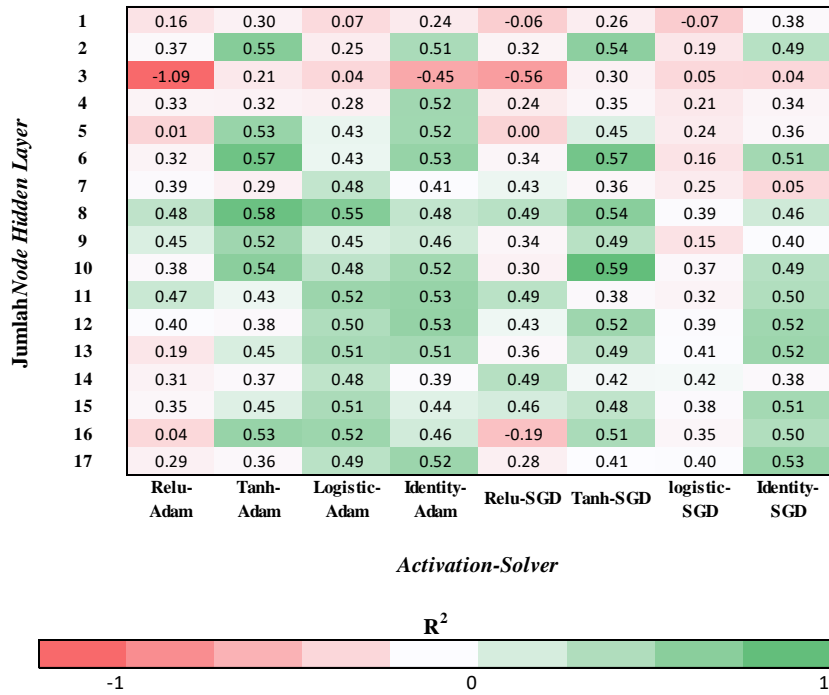
Validasi Model ANN

Setelah melakukan *training* maka selanjutnya kinerja model divalidasi menggunakan data yang belum digunakan sebagai proses belajar. Data validasi yang digunakan menggunakan 10% data yang dimiliki. Tujuan dari validasi ini adalah untuk memastikan bahwa model tersebut memiliki kemampuan untuk menggeneralisasi data-data yang ditetapkan dalam *training* yang dilakukan (Pooya Nejad et al., 2009; Pham, dkk. 2020; Zhang, dkk, 2021). Kriteria yang digunakan untuk mengevaluasi prediksi kinerja ANN adalah menggunakan koefisien determinasi (R^2).

HASIL DAN PEMBAHASAN

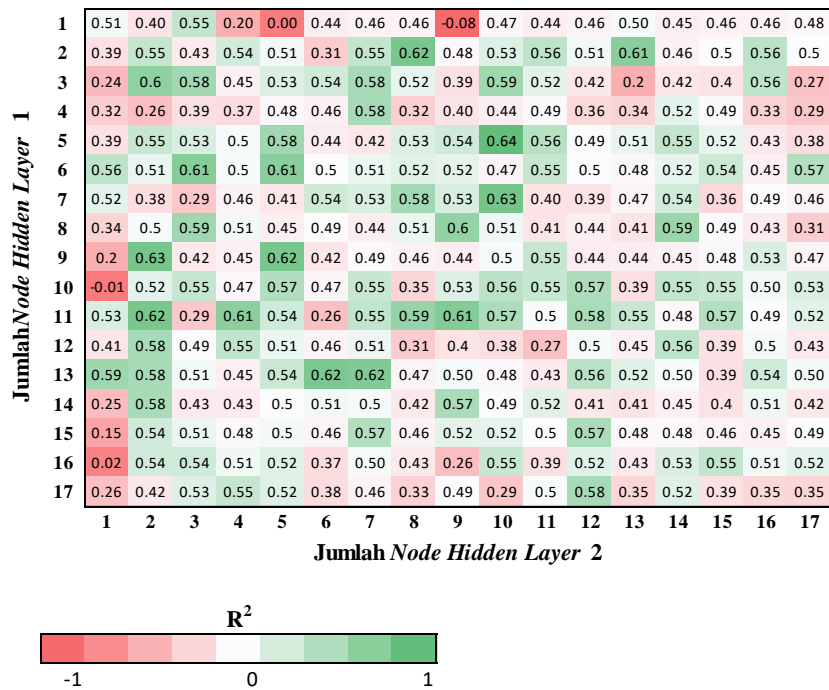
Analisa Model ANN

Model MLP Regressor memiliki beberapa parameter yang sangat penting, yaitu *hidden layer*, fungsi aktivasi dan *learning rate*. Pencarian model yang optimal dimulai dengan menentukan arsitektur model (yaitu jumlah *hidden layer* dan *node*). Satu lapisan tersembunyi dapat mendekati fungsi kontinu apa pun asalkan bobot koneksi yang digunakan cukup (Hornik et al., 1989; Raissi, 2019). Namun, pada penelitian ini dilakukan pendekatan *trial-and-error* menggunakan model dengan satu *hidden layer* dan model dengan dua lapisan *hidden layer* untuk menentukan nilai parameter jaringan yang optimum. *Activation*, *solver* dan *hidden layer* merupakan parameter yang penting pada model ANN. Sehingga penulis mengkombinasikan *activation*, *solver* dan *hidden layer* secara bersamaan. Hasil dari proses *training* yang bertujuan untuk menemukan arsitektur model terbaik, ditunjukkan pada Gambar 1.

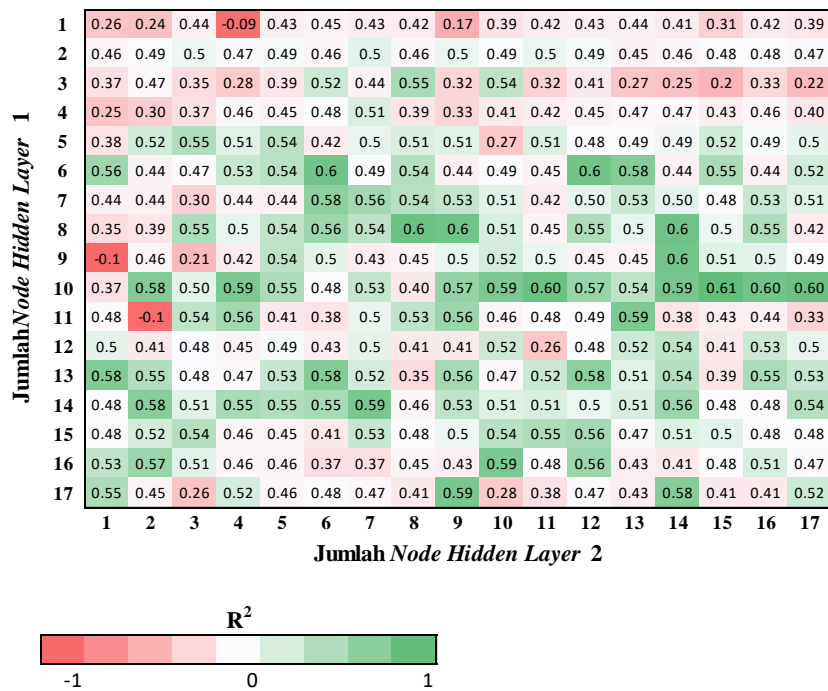


Gambar 1. Nilai R² model ANN dengan satu *Hidden Layer*

Dari gambar diatas menunjukkan bahwa model ANN dengan *hidden layer berjumlah satu* memiliki nilai R² terbesar yaitu 0,59 dengan jumlah *node* 10 pada *hidden layer* pertama. Dengan hasil R² yang terbilang masih cukup besar, maka peneliti melakukan percobaan dengan menambah jumlah *hidden layer* menjadi dua lapis. Hasil dari proses training model dengan dua *hidden layer* pada dua kombinasi *activation solver* yang memiliki akurasi terbesar ditunjukkan pada Gambar 2 jika dibandingkan dengan Gambar 3.

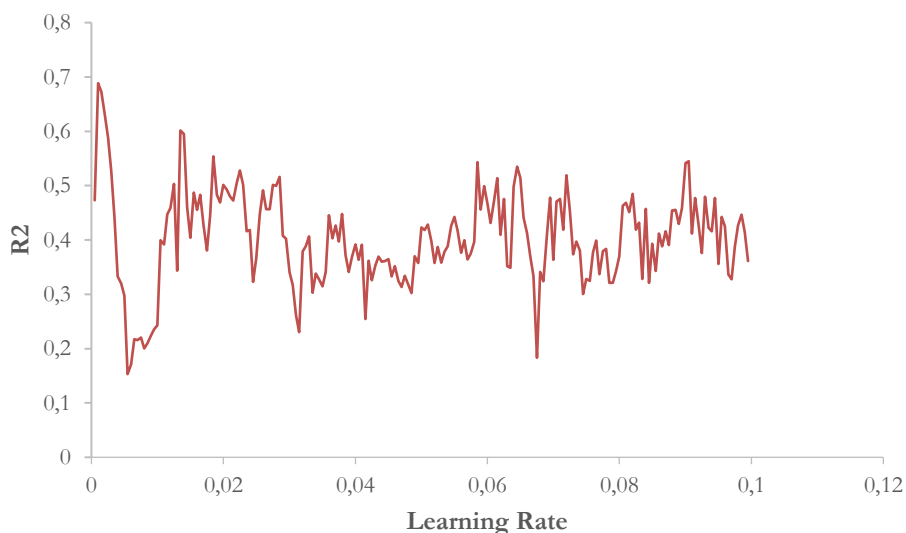


Gambar 2. Nilai R² model ANN dengan dua *Hidden Layer* dan Tanh-Adam



Gambar 3. Nilai R^2 model ANN dengan dua *Hidden Layer* dan *Tanh-sgd*

Dari gambar diatas menunjukkan bahwa model ANN dengan dua *hidden layer* memiliki nilai R^2 terbesar yaitu 0,64 dengan jumlah *node* 5 pada *hidden layer* pertama dan 10 *node* pada *hidden layer* kedua. Selanjutnya model dapat ditetapkan dengan *hidden layer* (5,10) dan fungsi aktivasi dengan kombinasi *Tanh-adam*. Selanjutnya model ANN dengan fungsi aktivasi *Tanh-adam* digunakan untuk mencari angka *learning rate* model. Pada penelitian ini penulis menguji nilai *learning rate* mulai dari 0,0005 dengan tingkat penambahan nilai sebesar 0,0005 sampai mencapai nilai 0,1. Hasil dari proses training model untuk mencari angka *learning rate* yang optimal ditunjukkan pada Gambar 4.




Gambar 4. Nilai R^2 model ANN dengan perubahan *learning rate*

Pengaruh dari perubahan *learning rate* terhadap performa model dapat dilihat dari Gambar 4. Dari gambar diatas menunjukkan bahwa model ANN memiliki performa terbaik ketika angka *learning rate* yang digunakan 0,001. Hal tersebut ditunjukkan dengan nilai R^2 terbesar yaitu 0,68. Dari gambar diatas juga dapat dilihat bahwa performa model ANN mengalami penurunan setelah angka *learning rate* berada di atas 0,001.


Hasil Prediksi

Model ANN dengan *hidden layer* (5,10), fungsi aktivasi Tanh-adam, dan *learning rate* 0,001 kemudian digunakan untuk memprediksi nilai penurunan fondasi tiang yang digambarkan dalam *load-settlement curve*. Pada penelitian ini, proses prediksi menggunakan data *testing* yang berjumlah 4 data fondasi tiang atau 10% dari jumlah data keseluruhan (39 data *load-settlement curve* fondasi tiang). Yang mana 4 data ini merupakan data diluar dari data *training*. Sehingga data *testing* tidak dipengaruhi oleh proses apa pun. Hal ini dimaksudkan agar hasil prediksi yang didapat benar-benar sesuai dengan model dan hasil *training* yang sebenarnya. Sehingga model ini mampu digunakan untuk penghitungan dengan data lainnya.


Pada penelitian didapatkan hasil testing dengan nilai R^2 sebesar 0,77, RMSE sebesar 174 kN. Pada Gambar 5 sampai Gambar 8 ditunjukkan hasil prediksi *load-settlement curve* fondasi tiang dengan model yang telah didapat. Pada Gambar 6 dan Gambar 8 dengan spesifikasi tiang uji adalah *concrete*, dapat dilihat bahwa hasil prediksi sudah mampu merepresentasikan hasil kurva yang cenderung baik. Pada Gambar 5 dan Gambar 7 hasilnya masih belum merepresentasikan data aktual di lapangan. Berdasarkan asumsi penulis ada spesifikasi tertentu yang mempengaruhi perbedaan ini meskipun kedua tiang adalah tiang bermaterial *steel*. Pada Gambar 5, 6 dan 7 hasil prediksi dibandingkan dengan data aktual, beban yang mampu diterima oleh data prediksi cenderung lebih besar meskipun dengan penurunan yang sama.



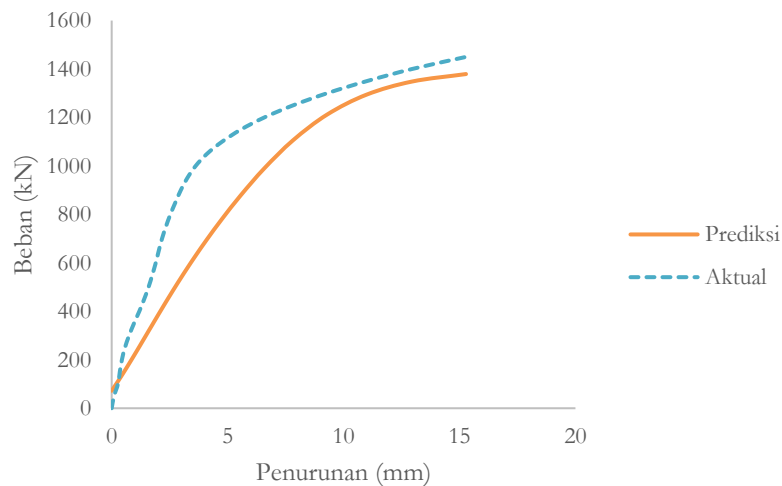
Gambar 5. Hasil uji 1



Gambar 6. Hasil uji 2



Gambar 7. Hasil uji 3



Gambar 8. Hasil uji 4

SIMPULAN

Model *artificial neural network* diaplikasikan untuk melakukan prediksi *load-settlement curve* khususnya pada tanah non-kohesif didapatkan hasil *testing* dengan R^2 bernilai 0,77 dan RMSE bernilai 174 kN sehingga metode *artificial neural network* bisa dikembangkan untuk melakukan prediksi *load-settlement curve*. Perancangan model *artificial neural network* untuk memprediksi nilai penurunan fondasi menghasilkan model arsitektur dengan; hidden layer 1: 5, hidden layer 2: 10, learning rate: 0.001, fungsi aktivasi hidden layer: tanah, fungsi aktivasi output: adam.

UCAPAN TERIMAKASIH

Ucapan terimakasih kepada Tuhan Yang Maha Esa atas rahmat-Nya yang selalu menuntun keberhasilan penelitian dari awal hingga akhir. Ucapan terimakasih penulis untuk orang tua dan saudara yang telah mendukung serta selalu memberi semangat dan doa. Terimakasih yang sebesar-besarnya untuk kelompok penelitian penulis yang sangat solid dari awal hingga akhir.

REFERENSI

- Aljarah, I., Faris, H. and Mirjalili, S., 2018. Optimizing connection weights in neural networks using the whale optimization algorithm. *Soft Computing*, 22, pp.1-15.
- Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43(1), 3–31. [https://doi.org/10.1016/S0167-7012\(00\)00201-3](https://doi.org/10.1016/S0167-7012(00)00201-3)
- Bradshaw, A. (2006). *Design and Construction of Driven Pile Foundations-Lessons Learned on the Central Artery/Tunnel Project*.
- Chen, W., Sarir, P., Bui, X.N., Nguyen, H., Tahir, M.M. and Jahed Armaghani, D., 2020. Neuro-genetic, neuro-imperialism and genetic programming models in predicting ultimate bearing capacity of pile. *Engineering with Computers*, 36, pp.1101-1115.
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623. <https://doi.org/10.7717/peerj-cs.623>
- Eslami, A., Moshfeghi, S., MolaAbasi, H., & Eslami, M. M. (2020). CPT equipment, performance, and records. In *Piezcone and Cone Penetration Test (CPTu and CPT) Applications in Foundation Engineering* (pp. 55–80). Elsevier. <https://doi.org/10.1016/B978-0-08-102766-0.00003-1>
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), 359–366. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)
- Jong, S.C., Ong, D.E.L. and Oh, E., 2021. State-of-the-art review of geotechnical-driven artificial intelligence techniques in underground soil-structure interaction. *Tunnelling and Underground Space Technology*, 113, p.103946.
- Luthfiani, F., Nurhuda, I., & Atmanto, I. D. (2017). ANALISIS PENURUNAN BANGUNAN PONDASI TIANG PANCANG DAN RAKIT PADA PROYEK PEMBANGUNAN APARTEMEN SURABAYA CENTRAL BUSINESS DISTRICT. *JURNAL KARYA TEKNIK SIPIL*, 6(2), 166–179. <http://ejournal-s1.undip.ac.id/index.php/jkts>
- Murlidhar, B.R., Sinha, R.K., Mohamad, E.T., Sonkar, R. and Khorami, M., 2020. The effects of particle swarm optimisation and genetic algorithm on ANN results in predicting pile bearing capacity. *International Journal of Hydromechatronics*, 3(1), pp.69-87.
- Pham, T.A., Tran, V.Q., Vu, H.L.T. and Ly, H.B., 2020. Design deep neural network architecture using a genetic algorithm for estimation of pile bearing capacity. *PLoS One*, 15(12), p.e0243030.
- Pooya Nejad, F., Jaksa, M. B., Kakhi, M., & McCabe, B. A. (2009). Prediction of pile settlement using artificial neural networks based on standard penetration test data. *Computers and Geotechnics*, 36(7), 1125–1133. <https://doi.org/10.1016/j.compgeo.2009.04.003>
- Raissi, M., Perdikaris, P. and Karniadakis, G.E., 2019. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational physics*, 378, pp.686-707.
- Shahin, M. A. (2016). State-of-the-art review of some artificial intelligence applications in pile foundations. *Geoscience Frontiers*, 7(1), 33–44. <https://doi.org/10.1016/j.gsf.2014.10.002>
- Zhang, W., Li, H., Li, Y., Liu, H., Chen, Y. and Ding, X., 2021. Application of deep learning algorithms in geotechnical engineering: a short critical review. *Artificial Intelligence Review*, pp.1-41.