

PENERAPAN ARTIFICIAL NEURAL NETWORK (ANN) DALAM MEMPREDIKSI KAPASITAS DUKUNG FONDASI TIANG

Raden Harya Dananjaya^{1*}, Sutrisno² dan Syahid Fitriady¹

¹Program Studi Teknik Sipil, Universitas Sebelas Maret

²Program Studi Teknik Elektro, Universitas Sebelas Maret

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

Email: dananjaya.harya@gmail.com

Abstract

In the last decades, there are many studies related to the prediction of foundation-bearing capacity using artificial neural networks (ANN). The advantage of the ANN model over traditional methods in predicting the bearing capacity of the foundation is the ability of the ANN model to capture the nonlinear and complex relationship between the problem and the factors affecting the bearing capacity of the foundation. This study aims to determine the performance of the ANN model in predicting the value of the bearing capacity of the pile foundation using CPT data and pile load test. The method used in this study is an artificial neural network (ANN). Several scenarios employing various numbers of hidden layers, activation functions, and learning rates are investigated. The scenario having the most accurate prediction in the k -fold cross-validation is used to predict the bearing capacity of the pile foundation. Using testing data, the R^2 of the model is 0.91 which indicates that the artificial neural network model can be applied to predict the bearing capacity of the pile foundation.

Keywords: ANN, bearing capacity, CPT, k -folds cross-validation, pile load test

Abstrak

Beberapa tahun terakhir banyak penelitian terkait prediksi kapasitas dukung fondasi menggunakan *artificial neural network* (ANN). Keuntungan dari model ANN dibandingkan metode tradisional dalam prediksi kapasitas dukung fondasi adalah kemampuan model ANN untuk menangkap hubungan non linier dan kompleks antara kapasitas dukung dan faktor-faktor yang mempengaruhinya. Penelitian ini bertujuan untuk mengetahui performa model ANN dalam memprediksi nilai kapasitas dukung fondasi tiang menggunakan data CPT dan *pile load test*. Metode yang digunakan adalah *artificial neural network* (ANN) dengan menggunakan beberapa skenario berdasarkan variasi *hidden layer*, fungsi aktivasi, dan *learning rate*. Model dengan performa paling baik berdasarkan metode *k-folds cross validation* digunakan untuk memprediksi kapasitas dukung fondasi tiang. Hasil penelitian ini menunjukkan bahwa metode kecerdasan buatan dengan model *artificial neural network* dapat diterapkan dalam memprediksi kapasitas dukung fondasi tiang. Model yang dihasilkan mampu memprediksi nilai kapasitas dukung dengan nilai R^2 mencapai 0,91 saat proses *testing*.

Kata Kunci : ANN, CPT, kapasitas dukung, k -folds cross validation, pile load test

PENDAHULUAN

Kapasitas dukung fondasi dan jumlah beban yang dipikul perlu diperhitungkan saat perencanaan fondasi. Jika perencanaan fondasi tidak dilakukan secara baik, maka dapat terjadi keruntuhan dan penurunan yang mengakibatkan kegagalan pada bangunan. Agar bisa merencanakan fondasi yang sesuai, dibutuhkan data penyelidikan tanah yang akurat sehingga bisa dilakukan pemilihan jenis fondasi yang sesuai. Ada dua jenis fondasi yang sering digunakan dalam konstruksi yaitu, fondasi dangkal dan fondasi dalam. Jenis fondasi dangkal meliputi fondasi memanjang, fondasi telapak, fondasi rakit, dan fondasi sumuran. Sedangkan yang termasuk jenis fondasi dalam yaitu, fondasi tiang dan fondasi bor.

Interaksi antara fondasi tiang dan tanah adalah kompleks dan tidak sepenuhnya dipahami. Hal tersebut menjadi batasan dan mengakibatkan ketidakberhasilan banyak metode untuk memprediksi kapasitas dukung fondasi tiang dengan akurat (Fatehnia & Amrinia, 2018). Metode yang paling akurat yang dapat digunakan untuk menentukan kapasitas dukung fondasi tiang adalah berdasarkan hasil uji beban tiang di lapangan, namun pengujian tersebut mahal, memakan waktu, dan memerlukan ketersediaan tenaga ahli untuk melakukannya (Coduto, 1994). Penelitian ini bertujuan untuk mengetahui performa model ANN dalam memprediksi nilai kapasitas dukung fondasi tiang menggunakan data CPT dan *pile load test*.

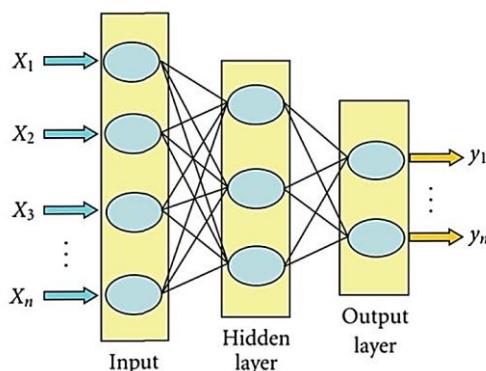
Kapasitas Dukung Fondasi

Daya dukung (*bearing capacity*) merupakan kemampuan tanah di sekitar fondasi untuk menahan beban yang tersalurkan dari struktur di atasnya. Pendekatan statis dan dinamis dapat digunakan untuk menghitung kapasitas

tiang. Perhitungan statis dilakukan dengan melihat kualitas teknis tanah. Sebaliknya, perhitungan dinamis dilakukan dengan menghitung kapasitas ultimit menggunakan data yang dikumpulkan dari data hasil perhitungan kapasitas tiang dan dicek ulang dengan melakukan pengujian tiang (Hardiyatmo, 2008).

Artificial Neural Network (ANN)

Artificial neural network (ANN) adalah pendekatan komputasi lunak yang mencoba meniru proses transfer informasi otak manusia. Secara umum, *artificial neural network* (ANN) adalah teknik pendekatan fungsi yang dapat digunakan ketika sifat kontak antara *input* dan *output* sangat kompleks dan non linier (Garrett, 1994). *Artificial neural network* (ANN) diciptakan sebagai model jaringan terdistribusi berdasarkan aktivitas otak manusia dan fungsi yang kompleks. Salah satu model arsitektur ANN yang paling menonjol adalah *multilayered perceptron* (MLP) yang dapat dilihat pada Gambar 1.



Gambar 1. *Multilayered perceptron* (Fatehnia & Amiran, 2018)

Model MLP terdiri dari neuron dan lapisan yang dihubungkan oleh bobot dan sangat baik dalam mendekati fungsi dalam ruang berdimensi tinggi (Du et al., 2002). Modifikasi bobot (w) antara lapisan dan neuron menentukan kinerja jaringan model. MLP dapat mempelajari fungsi non linier untuk klasifikasi atau regresi. Di antara lapisan *input* dan *output* ada parameter yang berupa satu atau lebih lapisan non linier, yang disebut lapisan tersembunyi atau *hidden layer*. Sebuah *hidden layer* akan melakukan transformasi non linier dari *input* yang dimasukkan ke dalam jaringan. *Hidden layer* bervariasi tergantung pada fungsi jaringan ANN dan bobot yang terkait. Selain parameter *hidden layer*, ada beberapa parameter yang berpengaruh dalam kinerja ANN yaitu fungsi aktivasi dan *learning rate*.

Fungsi aktivasi adalah parameter yang berguna untuk menentukan fungsi matematika yang akan digunakan suatu model *machine learning* untuk mengelola data *input* sehingga bisa didapatkan nilai *output* yang diinginkan. Beberapa fungsi aktivasi yang terkenal adalah fungsi Identity, Logistic/Sigmoid, Tanh, dan ReLU. Fungsi Identity, disebut juga fungsi linier, adalah fungsi yang selalu mengembalikan nilai yang sama yang digunakan sebagai argumennya. Fungsi Logistic, disebut juga fungsi sigmoid, adalah fungsi yang mengambil nilai real apa pun sebagai nilai *input* dan *output* dalam kisaran 0 hingga 1. Fungsi Tanh, disebut juga *hyperbolic tangent* sangat mirip dengan fungsi aktivasi sigmoid/logistic, bahkan memiliki bentuk S yang sama dengan perbedaan rentang keluaran -1 sampai 1. Fungsi ReLU, disebut juga *rectified linear unit* adalah fungsi aktivasi non linier. Fungsi ReLU hanya akan mengaktifkan neuron jika *output* dari transformasi linier lebih dari 0. Ini berarti pada suatu waktu hanya beberapa neuron yang diaktifkan membuat jaringan menjadi efisien dan mudah untuk perhitungan.

Learning rate adalah suatu parameter yang digunakan untuk mengontrol kecepatan, dimana algoritma memperbarui bobot dari jaringan dengan memperhatikan penurunan nilai *error*. Jika *learning rate* yang digunakan terlalu kecil maka model *machine learning* akan membutuhkan waktu yang lebih lama dalam melakukan *training* model untuk memperbarui bobot dari jaringan. Namun, jika *learning rate* yang digunakan terlalu besar maka *machine learning* dalam memperbarui bobot dari jaringan menjadi tidak optimal. Rentang nilai dari parameter *learning rate* adalah 0 hingga 1,0.

R-Square (R^2) (Koefisien Determinasi)

R-Squared (R^2) atau koefisien determinasi adalah metrik untuk menilai kinerja model pembelajaran mesin regresi. Skor R^2 memberikan indikasi seberapa besar variasi (data *output*) bisa diprediksi oleh variabel independen (data *input*) dalam model. Berikut adalah persamaan dari koefisien determinasi dapat dilihat pada Persamaan [1].

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \dots [1]$$

keterangan :

y_i = nilai aktual

\hat{y}_i = nilai prediksi

\bar{y} = nilai rata-rata

Root Mean Square Error (RMSE)

Root Mean Square Error atau RMSE menggambarkan deviasi standar sampel dari perbedaan antara nilai yang diprediksi dan yang diamati. RMSE memiliki rentang nilai dari 0 hingga ∞ . Semakin kecil nilai RMSE maka semakin baik hasil prediksi model. Nilai RMSE dapat dihitung dengan Persamaan [2].

$$RMSE = \sqrt{\frac{1}{n} \sum_1^n (Qu_{act} - Qu_{ann})^2} \quad \dots \dots \dots [2]$$

dengan,

n = jumlah data

Qu_{act} = kapasitas dukung fondasi aktual (kN)

Qu_{ann} = kapasitas dukung fondasi prediksi ANN (kN)

K-Fold Cross Validation

Cross validation atau validasi silang adalah metode statistik yang digunakan untuk memperkirakan keterampilan model *machine learning*. Salah satu teknik validasi silang adalah *k-fold cross validation*. Huruf *k* melambangkan jumlah pembagian kelompok data yang kita inginkan saat validasi silang. Pada metode *k-fold cross validation*, data yang digunakan dalam membangun model akan dibagi menjadi *k* bagian data (*k-folds*). Proses *testing* akan dilakukan pada 1 kelompok data, sedangkan proses *training* dilakukan pada sisa kelompok data lainnya. Proses tersebut dilakukan secara bergiliran dengan mengambil 1 bagian data secara bergantian pada setiap skenario *training* dan *testing*.

METODE

Pengumpulan Data

Data yang digunakan pada penelitian ini adalah data sekunder pengujian *cone penetration test* (CPT) dan *pile load test* dari literatur jurnal yang diambil dari Albiero et al. (1995), Altaee et al. (1992), Avasarala et al. (1994), Gambini (1985), Haustorfer & Plesiotis (1988), Hill (1987), Horvitz et al. (1981), Laier (1994), Matsumoto et al. (1995), Mayne & Harris (1993), Nevels & Sneathen (1994), Niazi & Mayne (2010), O'Neill (1986), Reese et al. (1988), Robertson et al. (1988), Tucker & Briaud (1988), Tumay & Fakhroo (1981), Viergever (1982), Weber (1987), Yen et al. (1989), dan Ebrahimian (2011) dalam Ebrahimian & Movahed (2017) serta data dari Alsamman (1995) dan Eslami (1997) dalam Alkroosh & Nikraz (2011) dengan jumlah keseluruhan 87 data.

Data CPT yang didapatkan yaitu nilai tahanan konus (q_c) dan tahanan gesek selubung bikonus (f_s). Data tahanan konus (q_c) yang digunakan adalah rata-rata resistensi ujung kerucut di atas zona pengaruh. Menurut Eslami & Fellenius (1997), zona pengaruh adalah dari $4D$ di bawah kaki tiang hingga $8D$ dan $2D$ di atasnya ketika tiang melewati tanah yang lemah ke padat dan padat ke tanah yang lemah. Untuk tahanan gesek selubung bikonus (f_s), rata-rata digunakan di seluruh panjang tiang yang tertanam sebagai zona pengaruh. Sedangkan dari data *pile load test* didapat *feature* berupa diameter fondasi, panjang fondasi, material, bentuk penampang, metode instalasi, dan nilai kapasitas dukung fondasi. Mengenai tiang non lingkaran, menurut Ebrahimian & Movahed (2017) diameter yang digunakan adalah diameter lingkaran dengan luas penampang sama dengan luas penampang tiang.

Penentuan *Input* dan *Output* Data

Pada perancangan model ANN, penentuan *input* dan *output* data adalah hal yang penting. Kapasitas dukung fondasi ditetapkan sebagai data *output* dalam penelitian ini. Sedangkan untuk variabel yang mempengaruhi prediksi kapasitas tiang disajikan ke dalam model ANN sebagai data *input*. Dalam penelitian ini, variabel yang digunakan adalah diameter tiang (D), panjang tiang (L), tahanan gesek selubung bikonus (f_s), nilai tahanan konus (q_c), *pile material*, jenis fondasi tiang (bentuk penampang), dan metode pemasangan fondasi tiang.

Klasifikasi Sampel Data

Sampel data yang tersedia dikelompokkan menjadi dua set data, yaitu data *training* untuk membangun model ANN dan data *testing* untuk memvalidasi kinerja model ANN yang digunakan. Pada penelitian ini proporsi pembagian data yaitu 90% (78 data) untuk proses *training* model dan 10% (9 data) untuk proses prediksi atau *testing* model. Peneliti sebelumnya sudah mencoba dengan berbagai proporsi pembagian data dan didapat bahwa proporsi 90% *training* dan 10% *testing* memiliki hasil yang paling baik dengan data sekunder yang dimiliki. Data *training* digunakan untuk membangun dan menyempurnakan bobot koneksi antar input data. Data *testing* digunakan untuk menghitung kinerja model ANN di lingkungan yang diterapkan.

Training dan Testing Model ANN

Proses mengoptimalkan bobot koneksi dikenal sebagai *training* atau *learning*. Teknik *back-propagation*, yang didasarkan pada penurunan gradien orde pertama, adalah pendekatan yang paling sering digunakan untuk menentukan kombinasi bobot yang optimal dari model ANN. Proses pengujian model ANN dilakukan setelah proses *training* model selesai. Model ANN diuji menggunakan data *testing*. Sampel data yang digunakan merupakan data yang tidak digunakan selama proses *training* model. Tujuan dari pengujian ini adalah untuk memastikan keakuratan model ANN dengan membandingkan hasil prediksi model ANN terhadap nilai *bearing capacity* dari pengujian lapang.

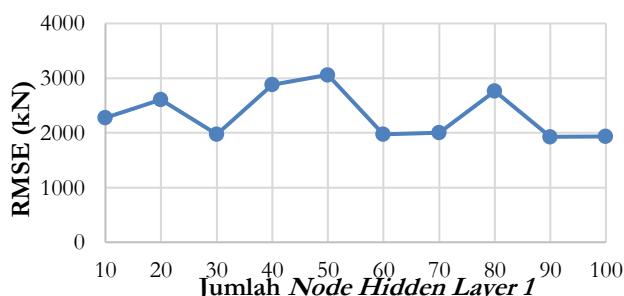
Validasi Model ANN

Metode yang digunakan dalam validasi model adalah *10-fold cross validation* dengan metrik *R-Squared* (R^2) dan *root-mean-square error* (RMSE). Pada metode *10-fold cross validation*, data yang digunakan dalam membangun model (data *training*) akan dibagi menjadi 10 bagian data (*10-folds*). Proses *training* dilakukan pada 9 bagian pertama data, sedangkan proses *testing* dilakukan pada 1 bagian data sisanya. Proses tersebut dilakukan secara bergiliran dengan mengambil 1 bagian data secara bergantian pada setiap skenario *training* dan *testing*.

HASIL DAN PEMBAHASAN

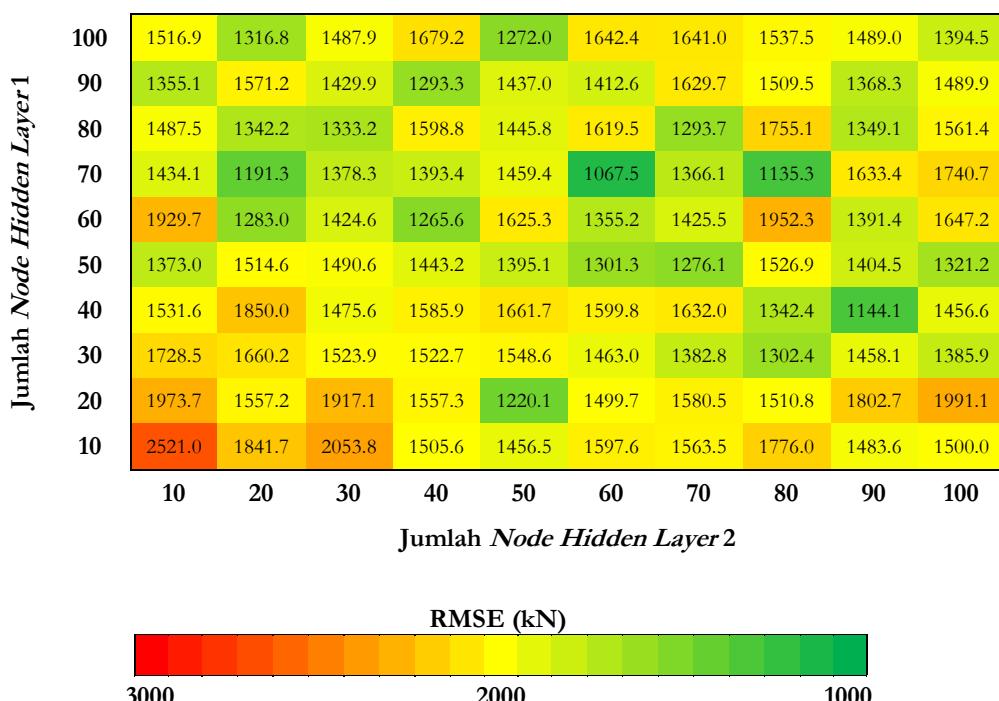
Analisa Model

Model MLPRegressor 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*). Hornik et al., (1989) merekomendasikan bahwa satu lapisan tersembunyi dapat mendekati fungsi kontinu apa pun asalkan bobot koneksi yang digunakan cukup. 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. Pada penelitian ini terdapat 10 variasi jumlah *node* yang digunakan pada setiap *hidden layer*, yaitu 10, 20, 30, 40, 50, 60, 70, 80, 90, 100. Hasil dari proses *training* yang bertujuan untuk menemukan arsitektur model terbaik, ditunjukkan pada Gambar 2.



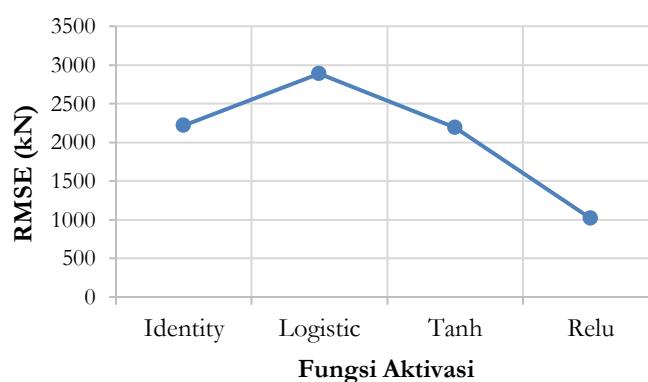
Gambar 2. Nilai RMSE model ANN dengan jumlah *Hidden Layer* 1

Gambar 2 menunjukkan bahwa model ANN dengan *hidden layer berjumlah satu* memiliki nilai RMSE terkecil pada jumlah *node* 60, yaitu 1970.13 kN. Dengan hasil RMSE yang terbilang masih cukup besar, maka peneliti melakukan percobaan dengan menambah jumlah *hidden layer* menjadi dua lapis. Hasil dari proses *training* model dengan jumlah *hidden layer* dua ditunjukkan pada Gambar 3.



Gambar 3. Nilai RMSE model ANN dengan Jumlah *Hidden Layer* 2

Gambar 3 menunjukkan pengaruh penggunaan 2 *hidden layer* terhadap nilai RMSE. Semakin hijau warna dari kotaknya, menunjukkan bahwa semakin kecil nilai RMSE. Model ANN dengan dua *hidden layer* memiliki nilai RMSE terkecil jika jumlah *node* pada *hidden layer* pertama adalah 70 dan jumlah *node* pada *hidden layer* kedua adalah 60, yaitu 1067.51 kN. Selanjutnya model dengan jumlah *node* yang paling optimum digunakan untuk mencari fungsi aktivasi. Untuk menentukan fungsi aktivasi yang akan digunakan, peneliti mencoba menerapkan 4 (empat) fungsi aktivasi secara bergantian, yaitu Identity, Logistic, Tanh, dan , ReLU. Hasil dari training model untuk mencari fungsi aktivasi yang optimal ditunjukkan pada Gambar 4.



Gambar 4. Nilai RMSE model ANN dengan Fungsi Aktivasi Berbeda

Gambar di atas menunjukkan bahwa model ANN dengan fungsi aktivasi ReLU memiliki nilai RMSE terkecil yaitu 1016.27 kN. Selanjutnya model ANN dengan fungsi aktivasi ReLU digunakan untuk mencari angka *learning rate*

model. Pada penelitian ini ditetapkan nilai parameter *learning rate*-nya sebesar 0,001; 0,01; 0,1; 0,15; 0,2; 0,25; 0,3; 0,35; 0,4; 0,45; 0,5; 0,55; 0,6; 0,65; 0,7; 0,75; 0,8; 0,85; 0,9; 0,95; 1,0. Hasil dari proses training model untuk mencari angka *learning rate* yang optimal ditunjukkan pada Gambar 5.



Gambar 4. Nilai RMSE model ANN dengan perubahan *learning rate*

Pengaruh dari perubahan *learning rate* terhadap performa model dapat dilihat di Gambar 5. Gambar 5 menunjukkan bahwa model ANN memiliki performa terbaik ketika angka *learning rate* yang digunakan 0,5. Hal tersebut ditunjukkan dengan nilai RMSE terkecil yaitu 861,61 kN.

Hasil Prediksi

Model ANN dengan jumlah *hidden layer* 2 (70 node pada *hidden layer* pertama dan 60 node pada *hidden layer* 2), fungsi aktivasi ReLU, dan *learning rate* 0,5 digunakan untuk memprediksi nilai kapasitas dukung fondasi tiang. Pada penelitian ini, proses prediksi menggunakan data *testing* yang berjumlah 9 data atau 10% dari jumlah data keseluruhan (87 data). Hasil prediksi model ANN dapat dilihat pada Tabel 1.

Tabel 1. Hasil prediksi kapasitas dukung fondasi tiang dengan ANN

No. Data	L (m)	D (m)	q_c (MPa)	f_s (MPa)	<i>Pile Material</i>	Type	<i>Installation Method</i>	Qu (kN)		Selisih (kN)
								Aktual	Prediksi	
69	25.00	1.010	10.20	0.011	Steel	Pipe	Driven	7849	6534.57	1314.43
24	16.20	0.301	19.74	0.080	Steel	Pipe	Driven	1310	3086.45	1776.45
32	9.40	0.350	2.74	0.060	Concrete	Round	Bored	645	246.58	398.42
76	20.40	0.350	5.00	0.086	Concrete	Round	Driven	1260	456.01	803.99
8	36.50	0.508	3.35	0.020	Concrete	Square	Driven	2950	2531.53	418.47
55	10.60	0.350	8.29	0.180	Concrete	Round	Bored	1160	632.41	527.59
60	11.50	0.299	7.11	0.200	Concrete	Round	Bored	1320	704.37	615.63
73	18.20	0.610	10.50	0.043	Concrete	Round	Driven	3600	3458.70	141.30
67	25.00	1.100	10.00	0.050	Concrete	Round	Bored	8662	8287.50	374.50
								Rata-rata	707.86	

Tabel 1 menunjukkan bahwa hasil prediksi nilai kapasitas dukung fondasi berbasis ANN sebagian besar bernilai lebih kecil daripada nilai Qu aktual. Namun, pada data nomor 24 hasil prediksinya bernilai lebih besar dibandingkan dengan nilai Qu aktual. Rata-rata selisih dari hasil prediksi dengan hasil uji lapangan adalah 707,86 kN dengan nilai selisih terbesar berada pada data nomor 24, yaitu 1776,45 kN

Validasi Model

Model ANN yang telah dibuat selanjutnya divalidasi dengan metode *10-fold cross validation*. *Cross validation* dilakukan untuk mengetahui kualitas model *machine learning* dalam memprediksi dengan perubahan pengacakan data training. Hasil *cross validation* dapat dilihat pada Tabel 2.

Tabel 2. Hasil *cross validation* model *MLPRegressor*

Jumlah Node		Fungsi Aktivasi	Learning Rate	Proses Testing		Cross Validation	
Hidden Layer 1	Hidden Layer 2			R ²	RMSE (kN)	R ²	RMSE (kN)
70	60	ReLU	Lr=0,5	0,91	861,6087	0,7483	1010,8796

Berdasarkan hasil validasi model pada Tabel 2, model ANN dengan jumlah *hidden layer 2* (70 node pada hidden layer pertama dan 60 node pada hidden layer 2), fungsi aktivasi ReLU, dan *learning rate* 0,5 memiliki nilai R² 0,91 saat proses prediksi dan nilai R² 0,7483 saat proses *cross validation*.

SIMPULAN

Dari penelitian dapat ditarik kesimpulan sebagai berikut:

1. Model *Artificial Neural Network* dengan parameter dengan jumlah *hidden layer 2* (70 node pada hidden layer pertama dan 60 node pada hidden layer 2), fungsi aktivasi ReLU, dan *learning rate* 0,5 menjadi kombinasi parameter terbaik dalam penelitian ini, hal ini ditunjukkan dengan nilai R² *cross validation* sebesar 0,7483.
2. Penerapan model *artificial neural network* dalam memprediksi kapasitas dukung fondasi tiang memiliki akurasi dengan nilai R² 0,91 dan nilai RMSE 861,6087 kN saat proses *testing*.

UCAPAN TERIMAKASIH

Ucapan terimakasih kepada Tuhan Yang Maha Esa atas rahmat-Nya yang selalu menuntun keberjalan 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

- Albiero J H, Sacilotto A C, Mantilla J N R, Teixeira C Z, & Carvalho D, 1995, "Sucessive Load Tests On Bored Piles", *Proceedings*.
- Alkroosh I & Nikraz H, 2011, "Correlation of Pile Axial Capacity and CPT Data Using Gene Expression Programming". *Geotechnical and Geological Engineering*. Vol. 29 No. 5, pp. 725–748.
- Alsamman, O. M., 1995, "The Use Of CPT For Calculating Axial Capacity Of Drilled Shafts". University of Illinois at Urbana-Champaign.
- Altaee A, Fellenius B H, & Evgin E, 1992, "Axial Load Transfer For Piles In Sand. I. Tests On An Instrumented Precast Pile", *Canadian Geotechnical Journal*, Vol. 29 No. 1, pp. 11–20.
- Avasarala S K V, Davidson J L, & McVay A M, 1994, "An Evaluation Of Predicted Ultimate Capacity Of Single Piles From Spile And Unpile Programs", *Proceedings Int. Conf. on Design and Construction of Deep Foundations, FHWA*. pp. 712–723.
- Coduto, D. P., 1994, "Foundation Design: Principles and Practices", Prentice Hall.
- Du K-L, Lai A K Y, Cheng K K M & Swamy M N S, 2002, "Neural Methods For Antenna Array Signal Processing: A Review". *Signal Processing*, Vol. 82 No. 4, pp. 547–561.
- Ebrahimian, B., 2011, "Interpretation Of Static Pile Load Tests Results: Iran LNG Project". Pire Co. Tehran.
- Ebrahimian B & Movahed V, 2017, "Application Of An Evolutionary-Based Approach In Evaluating Pile Bearing Capacity Using CPT Results", *Ships and Offshore Structures*, Vol. 12 No. 7, pp. 937–953.
- Eslami, A., 1997, "Bearing Capacity Of Piles From Cone Penetration Test Data", University of Ottawa. Canada.
- Eslami A & Fellenius B H, 1997, "Pile Capacity by Direct CPT and CPTU Methods Applied to 102 Case Histories". *Canadian Geotechnical Journal*, Vol. 34 No. 6.
- Fatehnia M & Amirinia G, 2018, "A Review Of Genetic Programming And Artificial Neural Network Applications In Pile Foundations", *International Journal of Geo-Engineering*. Vol. 9 No. 1, pp. 2.

- Gambini F, 1985, "Experience in Italy With Centricast Concrete Piles". *Proc. Int. Symp, on Penetrability and Drivability of Piles*. pp. 97–100.
- Garrett, J. H., 1994, "Editorial", *Journal of Computing in Civil Engineering*. Vol. 8 No. 2, pp. 129–130.
- Hardiyatmo, H. C., 2008, "Teknik Fondasi", Beta Offset.
- Haustorfer I & Plesiotis S, 1988. "Instrumented dynamic and static pile load testing at two bridge sites", *Fifth Australia-New Zealand Conference on Geomechanics: Prediction versus Performance; Preprints of Papers*.
- Hill, C., 1987, "Geotechnical report on indicator pile testing and static pile testing, berths 225-229 at Port of Los Angeles", CH2M Hill. Los Angeles.
- Hornik K, Stinchcombe M & White H, 1989, "Multilayer feedforward networks are universal approximators", *Neural Networks*. Vol. 2 No. 5, pp. 359–366.
- Horvitz G E, Stettler D R, & Crowser J C, 1981, *Comparison of Predicted and Observed Pile Capacity*. pp. 413–433.
- Laier, J. E., 1994, "Predicting the ultimate compressive capacity of long 12-H-74 steel pile", *Proc. Int. Conf. on Design and Construction of Deep Foundations*, pp. 1804–1818.
- Matsumoto T, Michi Y, & Hirano T, 1995, "Performance of axially loaded steel pipe piles driven in soft rock", *Journal of Geotechnical Engineering*. Vol. 121 No. 4, pp. 305–315.
- Mayne P W & Harris D E, 1993, "Axial Load-Displacement Behavior of Drilled Shaft Foundations in Piedmont Residuum", *FHWA Reference*. No. 41-30, pp. 2175.
- Nevels J B & Snethen D R, 1994, "Comparison of Settlement Predictions for Single Piles in Sand Based on Penetration Test Results", *Vertical and Horizontal Deformations of Foundations and Embankments*, pp. 1028–1038.
- Niazi F S & Mayne P W, 2010, "Evaluation of EURIPIDES pile load tests response from CPT data", *ISSMGE International Journal of Geoengineering Case Histories*. Vol. 1 No. 4, pp. 367–386.
- O'Neill, M. W., 1986, "Reliability of Pile Capacity Assessment by CPT in Overconsolidated Clay", pp. 237–256.
- Reese J D, O'Neill M W & Wang S T, 1988, "Drilled shaft tests, Interchange of West Belt Roll Road and US290 Highway, Texas", Lymon C. Reese and Associates. Austin. Texas.
- Robertson P K, Campanella R G, Davies M P & Sy A, 1988, "Axial capacity of driven piles in deltaic soils using CPT", *International Symposium on Penetration Testing: ISOPT-1*. Vol. 1, pp. 919–927.
- Tucker L M & Briaud J-L, 1988, "Analysis of the Pile Load Test Program at the Lock and Dam 26 Replacement Project".
- Tumay M T & Fakhroo M, 1981, "Pile Capacity in Soft Clays Using Electric QCPT Data", pp. 434–455.
- Viergever, M. A., 1982, "Relation between cone penetration and static loading of piles in locally strongly varying sand layers".
- Weber, L., 1987, "Efficiency improvement of steel H-bearing piles".
- Yen T-L, Lin H, Chin C-T & Wang R F, 1989, "Interpretation of Instrumented Driven Steel Pipe Piles", pp. 1293–1308.