

PENGARUH VARIABEL BEBAS DALAM ANALISIS KAPASITAS DUKUNG DAN PENURUNAN FONDASI TIANG MENGGUNAKAN CORRELATION BASED FEATURE SELECTION (CFS)

Raden Harya Dananjaya¹, Sutrisno², Taufiqah Apriliani¹

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

²Program Studi Teknik Elektro, Fakultas Teknik, Universitas Sebelas Maret Surakarta
Jl. Ir. Sutami 36 A, Kentingan, Jebres Surakarta 57126, Telp (0271)647069, Fax 662118

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

Abstract

The foundation is used to transmit construction loads into the ground in order to ensure structure stability. Estimating the bearing capacity and settlement of piles is very important. Because of its complexity, several assumptions were made in the foundation analysis. Artificial intelligence (AI) is used to simplify this problem without sacrificing model accuracy. This study discusses the contribution of each independent variable to the capacity of a pile foundation and its settlement using correlation-based feature selection (CFS). The pile capacity and settlement are estimated using an artificial neural network (ANN) and a support vector machine (SVM). The data, which consist of the cone penetration test (CPT), pile characteristics, and static load test data, are divided into training and testing data. After building models using training data, the models are validated using testing data. The accuracy of the models is measured with the coefficient of determination (R^2) and the root mean square error (RMSE). The results show that the cone resistance (q_c), which has an absolute coefficient of correlation ($|r|$) of 0,7672, has the highest correlation with the pile capacity, while the pile diameter (D), which has an absolute coefficient of correlation ($|r|$) of 0,4286, has the highest correlation with the pile settlement.

Keywords: Artificial intelligence, bearing capacity, CFS, foundation, settlement.

Abstrak

Fondasi berfungsi sebagai penyalur beban konstruksi ke tanah dan menstabilkan struktur pada bangunan. Estimasi kapasitas dukung dan penurunan fondasi menjadi salah satu bagian penting dalam perancangan bangunan. Dikarenakan perilaku tanah yang kompleks, beberapa asumsi digunakan dalam perancangan fondasi. Sistem kecerdasan buatan (AI) sering digunakan untuk mengatasi masalah tersebut. Penelitian ini membahas tingkat signifikansi variabel bebas terhadap hasil prediksi *artificial neural network* (ANN) dan *support vector machine* (SVM) menggunakan metode *correlation-based feature selection* (CFS). Tingkat akurasi diukur menggunakan koefisien determinasi (R^2) dan *root mean square error* (RMSE). *Data set* yang digunakan berasal dari pengujian *cone penetration test* (CPT), karakteristik tiang, dan pengujian beban tiang statis. Data kemudian dibagi menjadi data training dan testing. Setelah pembuatan model dengan data training, model divalidasi menggunakan data testing. Tingkat akurasi diukur menggunakan koefisien determinasi (R^2) dan *root mean square error* (RMSE). Hasil CFS menunjukkan bahwa faktor yang paling berpengaruh pada kapasitas dukung adalah hambatan konus (q_c) dengan nilai korelasi ($|r|$) sebesar 0,7672, sedangkan faktor yang paling berpengaruh terhadap penurunan fondasi tiang adalah diameter fondasi (D) dengan nilai korelasi ($|r|$) sebesar 0,4287.

Kata Kunci : CFS, fondasi, kapasitas dukung, kecerdasan buatan, penurunan

PENDAHULUAN

Perencanaan proyek konstruksi bangunan sipil tidak bisa lepas dari aspek geoteknik. Salah satu aspek yang sering dijumpai adalah besarnya kapasitas dukung dan penurunan fondasi. Fondasi berfungsi sebagai stabilitas suatu bangunan (Benbouras dkk., 2021). Fondasi harus direncanakan dengan cermat dan teliti agar mampu memikul beban sampai batas keamanan yang ditentukan. Perancangan desain fondasi memerlukan analisis fisik berbasis data kondisi lapangan dan dilakukan perhitungan beban rencana sesuai kebutuhan fungsi bangunan. Pada proses selanjutnya menghitung beban rencana sehingga dihasilkan asumsi desain fondasi yang aman untuk suatu bangunan konstruksi. Dalam hal ini dimungkinkan terjadinya asumsi-asumsi pada proses perhitungan yang mengakibatkan berkurangnya akurasi hasil perancangan (Shahin, 2016).

Penelitian mengenai kapasitas dukung dan penurunan fondasi terus mengalami perkembangan, salah satunya adalah prediksi kapasitas dukung dan penurunan fondasi menggunakan data uji *cone penetration test* (CPT). CPT merupakan salah satu uji lapangan yang akurat dengan kesalahan acak kurang dari 3% (Kordjazi dkk., 2014). Oleh karena itu, diharapkan penggunaan data CPT pada pemodelan kapasitas dukung dan penurunan fondasi dapat menghasilkan prediksi yang akurat.

Pada zaman ini penggunaan kecerdasan buatan lebih disarankan untuk menyelesaikan permasalahan dengan lebih sederhana dan akurat. Berdasarkan beberapa penelitian yang telah dilakukan sebelumnya, kecerdasan buatan menunjukkan potensi untuk melakukan prediksi yang lebih baik dari metode konvensional. Pada prosesnya untuk menghasilkan prediksi yang maksimal diperlukan pengoptimalan kinerja metode klasifikasi, yang bertujuan untuk meningkatkan akurasi dan pemilihan fitur yang optimal. Seleksi fitur mengacu pada pendekatan fitur terbaik dengan mengoptimalkan informasi guna memaksimalkan akurasi model (Zhang, 2019). Salah satu metode seleksi fitur yang memiliki kinerja yang sangat baik adalah *correlation based feature selection* (CFS) (Sánchez dkk., 2007).

Penelitian ini dilakukan untuk mengetahui pengaruh variabel bebas terhadap analisis kapasitas dukung dan penurunan fondasi tiang berbasis kecerdasan buatan. Hasil *dataset* yang telah terseleksi akan digunakan sebagai data prediksi pada kapasitas dukung dan penurunan fondasi sehingga dalam proses prediksi dapat menghasilkan data yang optimal. *Dataset* dalam pengujian ini menggunakan data pengujian CPT dari beberapa literatur jurnal. *Dataset* tersebut kemudian diproses menggunakan metode CFS untuk mengetahui korelasi antar variabel bebas dalam analisis kapasitas dukung dan penurunan fondasi. Penelitian ini diharapkan dapat mengeliminasi variabel yang kurang berpengaruh untuk mengoptimalkan kinerja model *machine learning* sehingga menghasilkan prediksi kapasitas dukung dan penurunan fondasi yang akurat.

DASAR TEORI

Kapasitas Dukung Fondasi

Kapasitas dukung (*bearing capacity*) adalah kemampuan maksimum tanah untuk menahan beban atau kemampuan tanah yang masih dapat mendukung beban tanpa mengalami keruntuhan. Ada beberapa teori secara analitis dan empiris untuk memprediksi kapasitas dukung fondasi tiang. Namun metode empiris lebih sering digunakan karena ketidakpastian dan banyaknya asumsi metode teoritis dalam memperkirakan perilaku tanah selama dan setelah pemasangan tiang pancang (Ebrahimian dkk., 2017). Kapasitas dukung ultimit dihitung menggunakan pendekatan berdasarkan data yang ada dan perlu dicek ulang menggunakan pengujian tiang (Hardiyatmo, 2011).

Penurunan Fondasi

Penurunan adalah perubahan volume tanah pada saat penambahan beban di atas permukaan yang mengakibatkan gerakan tertentu pada konstruksi. Penurunan terjadi akibat gangguan pada tegangan tanah saat pemancangan, ketidakpastian distribusi beban dari tiang ke tanah, mengalirnya air dari lapisan tanah dengan tekanan air pori tinggi ke lapisan tanah dengan tekanan air pori rendah, dll. Peningkatan air pori sering disebabkan oleh peningkatan jumlah beban yang ada pada struktur di atasnya. Penurunan tanah dipicu oleh beberapa faktor antara lain dimensi fondasi, modulus elastisitas, beban yang diterima, dll. (Hardiyatmo, 2011).

Variabel Bebas dalam Analisis Kapasitas Dukung dan Penurunan Fondasi

Variabel bebas yang digunakan dalam penelitian ini disesuaikan dengan data yang diperoleh berdasarkan uji CPT dan dikorelasikan dengan hasil uji pembebanan statis tiang. Variabel bebas yang digunakan dalam dataset kapasitas dukung dan penurunan fondasi tiang meliputi:

1. Beban (P)
Variabel beban didapatkan dari hasil uji pembebanan statis (*loading test*) untuk mengetahui kapasitas dukung ultimit tiang ketika menerima gaya aksial dan mengetahui hubungan antara beban dan penurunan fondasi. Pembebanan yang dilakukan berkisar antara 150% sampai 250% dari beban rencana.
2. Dimensi tiang
Dimensi pada fondasi tiang meliputi diameter fondasi (D) dan panjang fondasi (L). Diameter dan panjang fondasi tiang akan memiliki pengaruh terhadap nilai dari gaya gesek tiang terhadap tanah di sekitarnya. Data dimensi tiang pada penelitian ini diperoleh dari pengukuran pada tiang. Diameter tiang non lingkaran (kotak, kanal H, dll.), menggunakan perhitungan diameter lingkaran yang memiliki luas penampang sama dengan luas penampang tiang.
3. Jenis penampang tiang
Tipe fondasi disesuaikan dengan keadaan tanah di sekitar, prediksi kapasitas dukung tanah, biaya, mutu dan waktu yang telah dirancang sehingga menghasilkan bahan yang mudah pada proses pemasangan dengan biaya yang ekonomis. Pada penelitian ini tipe fondasi yang digunakan adalah pipa, kotak, lingkaran, dan kanal H.

4. Material tiang (*pile material*)
Material adalah bahan yang dipakai untuk membuat fondasi. Material suatu struktur dapat menentukan usia dari bangunan. Semakin berkualitas suatu material maka hasil dan ketahanan mutu akan sangat terjamin, begitu pun sebaliknya. Material fondasi pada penelitian adalah beton (*concrete*) dan baja (*steel*).
5. Metode instalasi (*installation method*)
Metode instalasi fondasi adalah metode yang digunakan untuk memasang fondasi pada tanah dengan memperhatikan kondisi lingkungan dan kondisi tanah di sekitar. Pada penelitian ini ada dua tipe instalasi fondasi yaitu tiang pancang dan tiang bor.
6. Tahanan konus (q_c) dan tahanan gesek (f_s)
Pengujian *cone penetration test* (CPT) mendapatkan data tahanan konus (q_c) dan tahanan gesek selubung bikonus (f_s). Tahanan konus merupakan nilai perlawanan tanah terhadap ujung konus yang dinyatakan dalam gaya per satuan luas. Nilai tahanan konus (q_c) diperoleh berdasarkan teori Eslami dan Fellenius (1997). Sedangkan tahanan gesek (f_s) adalah nilai perlawanan gesekan tanah terhadap selubung bikonus yang dinyatakan dalam gaya per satuan luas. Pada penelitian ini nilai tahanan konus (q_c) berasal dari rata-rata resistensi ujung kerucut di atas zona pengaruh ($8D$ di atas kedalaman ujung tiang dan $4D$ dibawahnya). Nilai tahanan gesek berasal dari rata-rata nilai tahanan gesek pada seluruh panjang tiang yang tertanam sebagai zona pengaruh.

Correlation Based Feature Selection (CFS)

Metode *correlation-based feature selection* (CFS) merupakan metode *preprocessing* data yang digunakan untuk mengevaluasi kemampuan prediktif dengan data yang relevan pada saat membuat suatu model agar performa model yang dibentuk meningkat. Metode ini mengukur kemiripan antara dua buah fitur. Metode CFS secara umum berfungsi sebagai penyeleksi fitur sehingga menghasilkan fitur atau variabel yang penting dan efektif, mengurangi jumlah data, memudahkan *preprocessing* data, mengurangi besarnya kesalahan yang disebabkan oleh data yang kurang akurat. Data yang lebih sedikit akan memudahkan peneliti dalam memproses data sehingga mengefektifkan waktu dan mencegah data yang eror atau tidak relevan masuk. Untuk menghasilkan data yang optimal, kekeliruan atau eror harus dikurangi sehingga hasil yang dikeluarkan menjadi lebih baik. Metode CFS apabila antar faktor yang dimasukkan berpengaruh linier maka nilai koefisien korelasinya adalah 1. Sedangkan apabila antar variabel tidak saling berpengaruh maka nilai koefisien korelasinya 0 (Blessie dkk.,2012).

Kalibrasi dan Validasi Model

Kalibrasi pada model digunakan untuk menemukan parameter yang memberikan performa terbaik terhadap model dan diperoleh dengan cara melakukan komparasi antara pengukuran aktual dan data hasil prediksi. Penelitian ini menggunakan kalibrasi dengan metode *artificial neural network* (ANN) dan *support vector machine* (SVM) untuk menemukan hasil prediksi terbaik. Validasi pada model merupakan suatu proses evaluasi model hasil *training* menggunakan data *testing* untuk memeriksa akurasi dan performa model terhadap data hasil observasi lapangan. Pada penelitian ini, data hasil penurunan dan kapasitas dukung fondasi tiang digunakan untuk validasi. Evaluasi hasil di gunakan koefisien determinasi (R^2) dan *root mean square error* (RMSE).

METODE

Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data sekunder pengujian *cone penetration test* (CPT) dan uji pembebanan statis dari literatur jurnal Albiero dkk. (1995), Altaee dkk. (1992), Avasarala dkk. (1994), Gambini, (1985), Haustorfer & Plesiotis (1988), Hill (1987), Horvitz dkk. (1981), Laier (1994), Mayne & Harris (1993), Nevels & Sneath (1994), Niazi & Mayne (2010), O'Neill (1986), Reese dkk. (1988), Robertson dkk. (1988), Tucker & Briaud (1988), Tumay & Fakhroo (1981), Viergever (1982), Weber (1987), Yen dkk. (1989) dalam Ebrahimian & Movahed (2017) dan Alkroosh & Nikraz (2011). Data variabel *input* untuk memprediksi kapasitas dukung meliputi: diameter fondasi (D), panjang fondasi (L), nilai hambatan konus (q_c), nilai tahanan gesek (f_s), material fondasi, tipe fondasi, dan metode instalasi. Sedangkan *dataset* prediksi penurunan menggunakan data *input* terdiri dari: dimensi fondasi (panjang dan diameter), nilai hambatan konus ujung tiang ($q_{c\ tip}$), nilai hambatan konus pada selimut tiang ($q_{c\ shaft}$), beban, material fondasi, tipe fondasi dan metode instalasi fondasi.

Pengolahan Data Kategorial

Pengolahan data kategorial dimaksudkan untuk mengubah data kategorial menjadi data numerik agar terbaca pada program *python*. Data tersebut harus dinyatakan ke dalam format numerik (*encoding*) agar dapat diolah menggunakan

formula matematika. Data kategorial yang di-*encoding*, seperti pada *dataset* kapasitas dukung dan penurunan fondasi, berupa: material fondasi, tipe fondasi dan metode instalasi.

Penyusunan Script untuk Features Selection

Pada proses seleksi variabel bebas menggunakan CFS, dilakukan peng-*input-an dataset* kapasitas dukung dan penurunan fondasi yang berasal dari uji CPT dan uji pembebanan tiang statis. Pengecekan jumlah data dilakukan untuk menghindari kesalahan pada sistem pemodelan. Data kapasitas dukung dan penurunan fondasi berdasarkan uji pembebanan statis tiang sebagai data target. Data diolah secara otomatis dan didapatkan nilai koefisien korelasi antar variabel. Selanjutnya data dianalisis untuk mendapatkan variabel yang optimal untuk prediksi kapasitas dukung dan penurunan fondasi.

Penentuan Korelasi Variabel Bebas

Variabel-variabel bebas yang ada dievaluasi tingkat pengaruhnya terhadap variabel terikatnya menggunakan CFS dengan bahasa pemrograman *python*. Hasilnya berupa koefisien korelasi (r). Nilai korelasi variabel yang kurang dari 0,005 dapat diabaikan atau dieliminasi (Benjamin dkk., 2018; Ioannidis, 2018).

Training Model

Metode ANN dan SVM digunakan untuk memprediksi kapasitas dukung dan penurunan fondasi. Pada pembuatan model, variabel bebas yang digunakan merupakan hasil dari tahapan *features selection* yang telah dilakukan sebelumnya, sehingga diharapkan model yang dibuat akan lebih efisien, optimal, dan akurat.

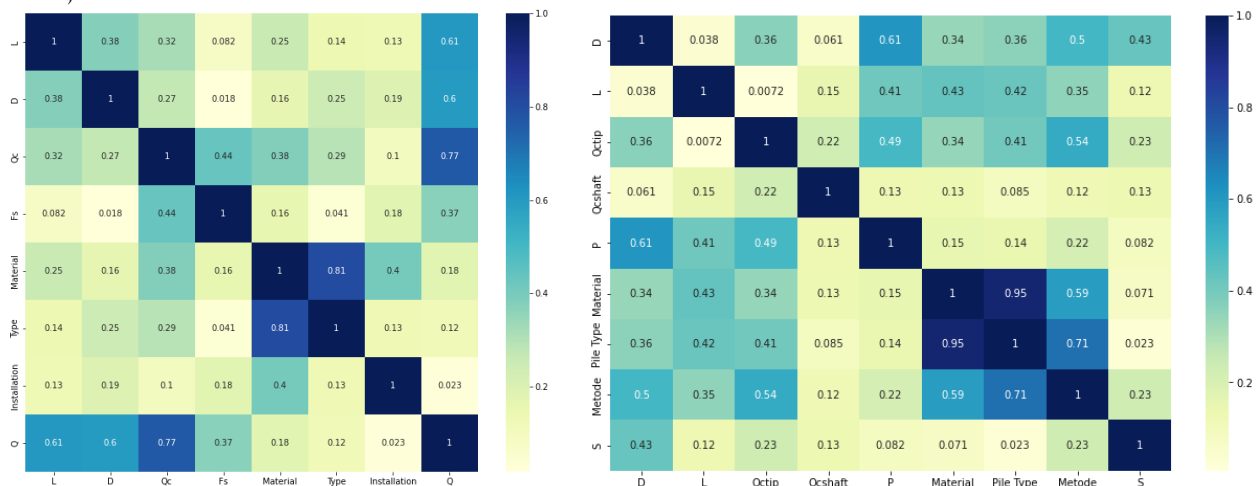
Validasi Data

Validasi data menggunakan koefisien determinasi (R^2) dan *root mean square error* (RMSE). Koefisien determinasi (R^2) menunjukkan kekuatan korelasi mutlak untuk mengukur kualitas permodelan. Model yang memiliki nilai koefisien determinasi (R^2) >0,85 dianggap sebagai model sangat baik (Suprayitno dkk., 2017). Sedangkan *root mean square error* (RMSE) adalah metode yang digunakan untuk mengukur tingkat kesalahan prediksi dengan mengukur perbedaan nilai dari data prediksi sebuah model dengan dataset penelitian. RMSE lebih tepat untuk mewakili kinerja model dengan melihat distribusi kesalahan (Chai dkk., 2014). Keakuratan model ditandai dengan nilai RMSE yang kecil.

HASIL DAN PEMBAHASAN

Hasil Features Selection Menggunakan Metode CFS

Hasil pengujian menggunakan metode CFS berupa nilai koefisien korelasi (r) antar faktor. *Feature* semakin berhubungan dengan data target, nilai koefisien korelasi semakin tinggi atau bahkan mendekati 1. Hasil penelitian disajikan dalam *heatmap* korelasi antar variabel bebas (*feature*) yang ditunjukkan pada Gambar 1 dengan *dataset* kapasitas dukung (Gambar 1a) dan penurunan fondasi (Gambar 1b). Nilai koefisien korelasi (r) juga ditunjukkan dengan visualisasi warna pada *heatmap* untuk mempermudah pengamatan hasil. Warna yang lebih gelap pada *cell* menunjukkan nilai korelasi variabel yang tinggi terhadap data target. Sedangkan, semakin terang warna *cell* menunjukkan nilai korelasi antar variabel semakin kecil.



(a) Korelasi variabel data kapasitas dukung (b) Korelasi variabel data penurunan
 Gambar 1. Heatmap nilai absolut koefisien korelasi antar variabel

Rekapitulasi hasil pengujian *dataset* kapasitas dukung dan penurunan fondasi dengan menggunakan metode CFS disajikan dalam Tabel 1 dan Tabel 2.

Tabel 1. Korelasi variabel-variabel bebas terhadap *dataset* kapasitas dukung fondasi

Variabel	Nilai Absolut Koefisien Korelasi	Keterangan
Nilai hambatan konus (q_c)	0,7672	Berpengaruh
Panjang fondasi (L)	0,6072	Berpengaruh
Diameter fondasi (D)	0,6001	Berpengaruh
Tahanan gesek selimut (f_s)	0,3690	Berpengaruh
Material Fondasi	0,1761	Berpengaruh
Tipe fondasi	0,1201	Berpengaruh
Metode instalasi fondasi	0,0226	Berpengaruh

Tabel 2. Korelasi variabel-variabel bebas terhadap *dataset* penurunan fondasi

Variabel	Nilai Absolut Koefisien Korelasi	Keterangan
Diameter fondasi (D)	0,4287	Berpengaruh
Panjang fondasi (L)	0,1239	Berpengaruh
Nilai hambatan konus ujung tiang ($q_{c\ tip}$)	0,2310	Berpengaruh
Nilai hambatan konus pada selimut tiang	0,1302	Berpengaruh
Metode instalasi fondasi	0,2296	Berpengaruh
Beban (P)	0,0819	Berpengaruh
Material fondasi	0,0708	Berpengaruh
Tipe fondasi	0,0229	Berpengaruh

Berdasarkan hasil Tabel 1 dan Tabel 2 *feature selection* dengan metode CFS menunjukkan semua variabel *input* berpengaruh terhadap target kapasitas dukung dan penurunan fondasi. Nilai absolut koefisien korelasi $|r| < 0,005$ dianggap tidak berpengaruh dan dapat dieliminasi.

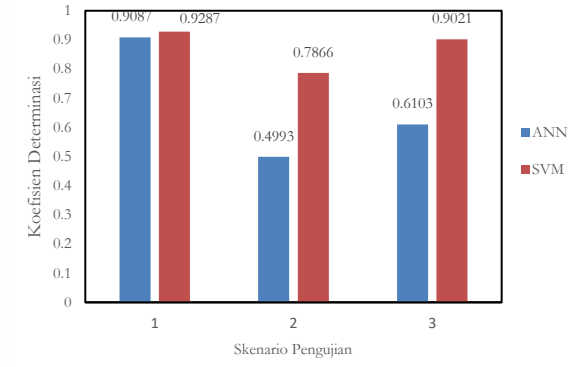
Validasi Metode CFS Pada Model

Korelasi antar variabel-variabel bebas pada model kapasitas dukung dan penurunan fondasi memiliki tingkat yang beragam. Untuk melihat pengaruh tahapan *features selection*, maka hasilnya perlu digunakan untuk memprediksi kapasitas dukung dan penurunan fondasi. Prediksi ini dilakukan dengan menggunakan metode ANN dan SVM. Hasil prediksi kapasitas dukung disajikan dalam Tabel 3, sedangkan hasil prediksi penurunan fondasi disajikan dalam Tabel 4. Validasi hasil *dataset* CFS menggunakan tiga skenario. Skenario pertama, semua variabel yang berpengaruh dimasukkan pada model *machine learning*. Skenario kedua, variabel yang memiliki nilai korelasi terbesar berdasarkan hasil *features selection* dieliminasi. Sedangkan skenario ketiga, hanya digunakan lima variabel terbaik berdasarkan hasil *features selection*. Pada kapasitas dukung fondasi nilai korelasi tertinggi berasal dari nilai hambatan konus (q_c), sedangkan pada penurunan fondasi nilai korelasi tertinggi berasal dari diameter fondasi (D).

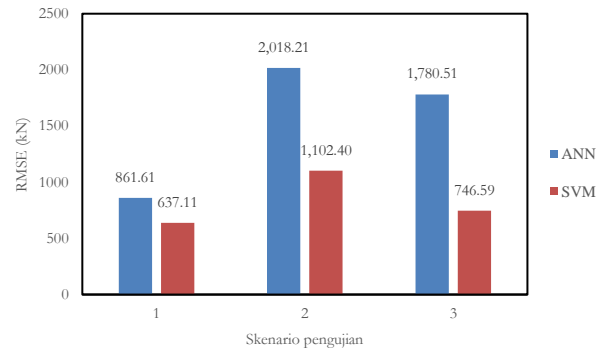
Tabel 3. Validasi hasil *features selection* pada dataset kapasitas dukung fondasi

Skenario	ANN		SVM	
	R^2	RMSE (kN)	R^2	RMSE (kN)
1	0,9087	861,6187	0,9287	637,1046
2	0,4993	2018,2124	0,7866	1102,3990
3	0,6103	1780,5189	0,9021	746,5950

Pada Tabel 3 keakuratan data ditunjukkan oleh R^2 dan $RMSE$. Hasilnya menunjukkan bahwa nilai R^2 pada kedua skenario terakhir mengalami penurunan dan nilai $RMSE$ -nya meningkat. Sehingga dapat disimpulkan akurasi data menurun apabila salah satu variabel dihilangkan. Grafik koefisien determinasi dan $RMSE$ pada ketiga skenario untuk *dataset* kapasitas dukung fondasi disajikan dalam Gambar 2-3.



Gambar 2. Nilai R^2 pada berbagai skenario untuk *dataset* kapasitas dukung fondasi

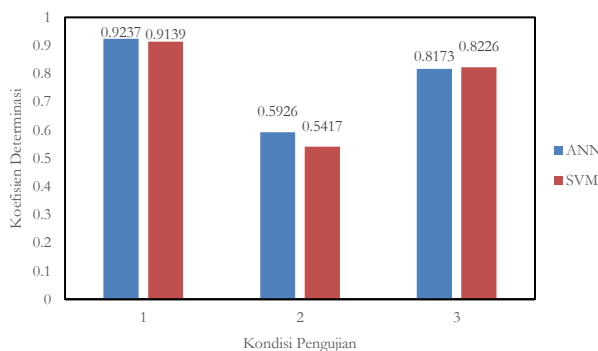


Gambar 3. Nilai $RMSE$ pada berbagai skenario untuk *dataset* kapasitas dukung fondasi

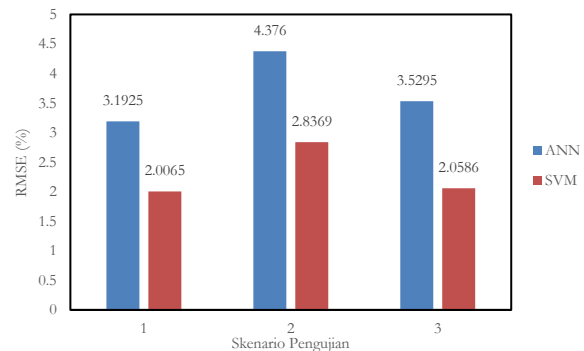
Tabel 4. Validasi *features selection* pada *dataset* penurunan fondasi

Skenario	ANN		SVM	
	R^2	$RMSE$ (%)	R^2	$RMSE$ (%)
1	0,9237	3,1925	0,9139	2,0065
2	0,5926	4,3760	0,5417	2,8369
3	0,8173	3,5295	0,8226	2,0586

Hasil Tabel 4 pada *dataset* penurunan fondasi menunjukkan bahwa apabila salah satu variabel bebas dihilangkan, maka nilai R^2 mengalami penurunan dan nilai $RMSE$ mengalami peningkatan. Hasil tersebut disajikan dalam Gambar 4 dan Gambar 5.



Gambar 4. Nilai R^2 pada berbagai skenario untuk *dataset* penurunan fondasi



Gambar 5. Nilai $RMSE$ pada berbagai skenario untuk *dataset* penurunan fondasi

Hasil validasi *features dataset* kapasitas dukung ditunjukkan pada Gambar 4 dan *dataset* penurunan ditunjukkan pada Gambar 5. Hasil pada *dataset* kapasitas dukung, performa terbaik dicapai oleh skenario pertama dengan R^2 tertinggi (0,9087 untuk ANN dan 0,9287 untuk SVM) dan $RMSE$ terendah (861,6187 kN untuk ANN dan 637,1046 kN untuk SVM). Setelah *feature* yang paling signifikan dihilangkan (skenario 2), performanya menjadi paling buruk di antara skenario lainnya, yaitu nilai R^2 -nya adalah yang paling rendah (0,4993 untuk ANN dan 0,7866 untuk SVM) dan nilai $RMSE$ -nya yang paling tinggi (2018,2124 kN untuk ANN dan 1102,3990 kN untuk SVM). Hasil skenario ketiga juga mengalami penurunan performa meskipun tidak sebesar pada skenario kedua, yaitu nilai R^2 -nya menjadi 0,6103 untuk ANN dan 0,9021 untuk SVM, sedangkan nilai $RMSE$ -nya menjadi 1780,5189 kN untuk ANN dan 746,5950 untuk SVM. Perilaku pada *dataset* penurunan fondasi tidak jauh berbeda, nilai R^2 pada skenario pertama

adalah tertinggi (0,9237 untuk ANN dan 0,9139 untuk SVM) dan RMSE-nya adalah yang terendah (3,1925 % untuk ANN dan 2,0065 % untuk SVM). Perilaku skenario kedua juga sama, performanya menjadi paling buruk dengan R^2 yang paling kecil (0,5926 untuk ANN dan 0,5417 untuk SVM) dan RMSE yang paling besar (4,3760 % untuk ANN dan 2,8369 % untuk SVM). Performa skenario ketiga berada di antara skenario pertama dan kedua dengan R^2 sebesar 0,8173 untuk ANN dan 0,8226 untuk SVM dan RMSE sebesar 3,5295 % untuk ANN dan 2,0586 % untuk SVM.

KESIMPULAN

Dari penelitian dapat ditarik kesimpulan sebagai berikut :

1. Hasil pada penelitian ini semua *features* memiliki nilai absolut koefisien korelasi lebih besar dari 0,005 sehingga bisa disimpulkan semua *features* berpengaruh signifikan terhadap model. Untuk membuktikan apakah hasil analisis CFS tersebut benar, tiga skenario model dibuat baik untuk *dataset* kapasitas dukung dan penurunan, yaitu 1) semua variabel yang signifikan dimasukkan dalam model, 2) menghilangkan satu variabel dengan korelasi tertinggi, dan 3) hanya menggunakan lima variabel dengan korelasi terbaik dalam model. Masing-masing model pada tiap-tiap *dataset* dibuat menggunakan dua metode yaitu ANN dan SVM.
2. Dari hasil yang dihasilkan ketiga skenario pengujian menunjukkan bahwa hasil analisis CFS yang digunakan pada model dengan metode ANN dan SVM sangat akurat karena mengalami penurunan nilai R^2 saat dilakukan pengurangan *features*, hasil tersebut selaras dengan absolut nilai koefisien korelasi bahwa semua *features* melebihi ambang batas 0,005. Semua variabel yang dipakai pada penelitian ini baik untuk *dataset* kapasitas dukung maupun penurunan sangat berpengaruh terhadap hasil prediksi. Jika variabel yang signifikan dihilangkan, maka akan berpengaruh terhadap performa model.

UCAPAN TERIMAKASIH

Ucapan terima kasih penulis tujukan kepada seluruh dosen, mahasiswa, dan laboran di Program Studi Teknik Sipil Universitas Sebelas Maret yang telah membantu dalam kegiatan penelitian dan penulisan artikel ini.

REFERENSI

- Albiero, J., Sacilotto, A., Mantilla, J., Teixeira, C., & Carvalho, D. (1995). *Successive 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*, 29(5), 725–748. <https://doi.org/10.1007/s10706-011-9413-1>
- 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*, 29(1), 11–20.
- Avasarala, S., Davidson, J., & McVay, A. (1994). *An evaluation of predicted ultimate capacity of single piles from spile and unpile programs*. 712–723.
- Benbouras Mohammed Amin, Laala Ghelani, and Lina Lefilef, & Alexandru-Ionu, t Petri, sor Hamma Zedira. (2021). *Forecasting the Bearing Capacity of the Driven Piles Using Advanced Machine-Learning Techniques*. <https://doi.org/10.3390/app112210908>
- Benjamin, D. J., Berger, J. O., Johannesson, M., Nosek, B. A., Wagenmakers, E.-J., Berk, R., Bollen, K. A., Brembs, B., Brown, L., Camerer, C., Cesarini, D., Chambers, C. D., Clyde, M., Cook, T. D., De Boeck, P., Dienes, Z., Dreber, A., Easwaran, K., Efferson, C., ... Johnson, V. E. (2018). Redefine statistical significance. *Nature Human Behaviour*, 2(1), 6–10. <https://doi.org/10.1038/s41562-017-0189-z>
- Blessie, E. C., & Karthikeyan, E. (2012). Sigmis: A Feature Selection Algorithm Using Correlation Based Method. *Journal of Algorithms & Computational Technology*, 6(3), 385–394. <https://doi.org/10.1260/1748-3018.6.3.385>
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247–1250. <https://doi.org/10.5194/gmd-7-1247-2014>
- Ebrahimian, B., & Movahed, V. (2017). Application of an evolutionary-based approach in evaluating pile bearing capacity using CPT results. *Ships and Offshore Structures*, 12(7), 937–953. <https://doi.org/10.1080/17445302.2015.1116243>
- Gambini, F. (1985). *Experience in Italy with centricast concrete piles*. 97–100.
- Hardiyatmo, H. C. (2011). *Teknik Fondasi 1.pdf* (2nd ed.). UGM Press.

- 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*.
- Horvitz, G., Stettler, D., & Crowser, J. (1981). *Comparison of predicted and observed pile capacity*. 413–433.
- Ioannidis, J. P. A. (2018). The Proposal to Lower P Value Thresholds to .005. *JAMA*, 319(14), 1429. <https://doi.org/10.1001/jama.2018.1536>
- Kordjazi, A., Pooya Nejad, F., & Jaksa, M. B. (2014). Prediction of ultimate axial load-carrying capacity of piles using a support vector machine based on CPT data. *Computers and Geotechnics*, 55, 91–102. <https://doi.org/10.1016/j.compgeo.2013.08.001>
- Laier, J. (1994). *Predicting the ultimate compressive capacity of long 12-H-74 steel pile*. 1804–1818.
- Mayne, P., & Harris, D. (1993). ‘Axial Load-Displacement Behavior of Drilled Shaft Foundations in Piedmont Residuuum. *FHWA Reference No. 41-30, 2175*.
- Nevels, J. B., & Sneath, D. R. (1994). *Comparison of settlement predictions for single piles in sand based on penetration test results*. 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*, 1(4), 367–386.
- O’Neill, M. W. (1986). *Reliability of pile capacity assessment by CPT in overconsolidated clay*. 237–256.
- Reese, J., O’Neill, M., & Wang, S. (1988). Drilled shaft tests, Interchange of West Belt Roll Road and US290 Highway, Texas. *Lymon C. Reese and Associates, Austin, Tex*.
- Robertson, P., Campanella, R., Davies, M., & Sy, A. (1988). *Axial capacity of driven piles in deltaic soils using CPT*. 919–927.
- Sánchez-Marono, N., Alonso-Betanzos, A., & Tombilla-Sanromán, M. (2007). Filter Methods for Feature Selection – A Comparative Study. In H. Yin, P. Tino, E. Corchado, W. Byrne, & X. Yao (Eds.), *Intelligent Data Engineering and Automated Learning—IDEAL 2007* (Vol. 4881, pp. 178–187). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-77226-2_19
- Shahin, M. A. (2016). State-of-the-art review of some artificial intelligence applications in pile foundations. *Geoscience Frontiers*, 12.
- Suprayitno, H., & Ratnasari, V. (2017). *Reflexion on linear regression trip production modelling method for ensuring good model quality*. 060013. <https://doi.org/10.1063/1.5011567>
- Tucker, L. M., & Briaud, J.-L. (1988). *Analysis of the pile load test program at the lock and dam 26 replacement project*. TEXAS A AND M UNIV COLLEGE STATION DEPT OF CIVIL ENGINEERING.
- Tumay, M. T., & Fakhroo, M. (1981). *Pile capacity in soft clays using electric QCPT data*. 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. *Arbed Research, Final Report, 7210*.
- Yen, T.-L., Lin, H., Chin, C.-T., & Wang, R. (1989). Interpretation of instrumented driven steel pipe piles. *Proc. Foundation Eng. Cong.: Current Principle and Practices, GSP No, 22, 1293–1308*.
- Zhang, P. (2019). A novel feature selection method based on global sensitivity analysis with application in machine learning-based prediction model. *Applied Soft Computing*, 85, 105859. <https://doi.org/10.1016/j.asoc.2019.105859>