

AKURASI PENGGUNAAN METODE SUPPORT VECTOR MACHINE (SVM) DALAM PREDIKSI KAPASITAS DUKUNG FONDASI TIANG

Raden Harya Dananjaya¹, Sutrisno², Nanda Milenia Dwi Rahmawati¹

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

Bearing capacity represents the strength of soil subjected to loading. Many methods can be used to estimate the bearing capacity of a foundation, such as artificial intelligence (AI). Support vector machine (SVM), which belongs to AI, is a popular method to predict the bearing capacity of a foundation. The advantage of using the SVM method is that it reduces assumptions in model building. This study is aimed at investigating the accuracy of SVM to predict the bearing capacity of a pile foundation using cone penetration test (CPT) data. The features (independent variables) used are pile diameter (D), pile length (L), pile material, pile type, installation method, conus resistance (q_c), and frictional resistance (f_s). For validation and calibration purposes, loading test data is used. The 10-fold cross-validation method is employed in the validation process. The result shows that the SVM model reaches its highest accuracy when the kernels C and γ are set to a polynomial kernel of 0.5 and 0.1, respectively. The ratio of 90:10 is the best ratio of training to testing data, which has an R^2 value of 0.9287 and an RMSE value of 637.109 kN in the testing process.

Keywords: Artificial intelligence, bearing capacity, k -fold cross validation, python, SVM

Abstrak

Kapasitas dukung merupakan hal penting yang harus diperhatikan pada saat merancang sebuah fondasi. *Artificial intelligence* dapat digunakan sebagai salah satu metode untuk memprediksi daya dukung fondasi. Salah satu metode di dalam *artificial intelligence* yang sering digunakan adalah *Support Vector Machine* (SVM). Keuntungan dari penggunaan metode SVM adalah pengurangan asumsi yang digunakan untuk memperoleh hubungan antara variabel bebas dengan variabel terikat pada proses prediksi. Penelitian ini bertujuan untuk mengetahui akurasi SVM dalam memprediksi kapasitas dukung fondasi dengan menggunakan data *cone penetration test* (CPT). Features atau variabel bebas yang digunakan sebagai *input* adalah diameter tiang (D), panjang tiang (L), pile material, pile type, installation method, nilai tahanan conus (q_c) dan tahanan gesek (f_s). Untuk melakukan kalibrasi dan validasi, digunakan data *loading test*. Proses validasi dilakukan dengan menggunakan metode *k-fold cross validation* yang pada penelitian ini menggunakan *10-folds cross validation*. Hasil penelitian menunjukkan bahwa model SVM yang menghasilkan akurasi terbaik adalah dengan menggunakan kernel *polynomial*, C sebesar 0,5 dan γ sebesar 0,1. Proporsi data *training* dan *testing* yang menghasilkan akurasi tertinggi adalah 90% : 10%, yang mana memiliki nilai R^2 dan RMSE pada proses *testing* sebesar 0,9287 dan 637,1087 kN, secara berturut-turut.

Kata Kunci : Artificial intelligence, k -fold cross validation, kapasitas dukung fondasi, python, SVM

PENDAHULUAN

Fondasi merupakan bagian penting pada sebuah konstruksi bangunan untuk menjaga bangunan agar tetap kokoh. Fungsi dari fondasi adalah meneruskan beban yang diterima oleh fondasi serta beratnya sendiri kepada tanah dan batuan yang berada di bawahnya.

Salah satu tujuan dalam perancangan fondasi adalah mengetahui besarnya kapasitas dukung tanah dasar fondasi. Prediksi kapasitas dukung fondasi telah banyak dirumuskan oleh banyak peneliti. Hasil dari prediksi kapasitas dukung tersebut telah mencapai keberhasilan namun masih terbatas dalam hal keakuratan (Iyad Alkroosh & Nikraz, 2012).

Salah satu alternatif yang dapat dilakukan dalam meningkatkan akurasi prediksi kapasitas dukung adalah dengan menggunakan *artificial intelligence*. Salah satu contoh dari penerapan *artificial intelligence* pada bidang teknik sipil adalah penggunaan metode *support vector machine* untuk memprediksi kapasitas dukung fondasi seperti pada penelitian yang dilakukan oleh Kordjazi et al. (2014). Metode *support vector machine* menghasilkan prediksi kapasitas dukung fondasi yang akurat tanpa menggunakan banyak asumsi dan simplifikasi seperti pada metode tradisional (Kordjazi et al., 2014).

Pada penelitian ini, dilakukan prediksi kapasitas dukung fondasi berbasis *artificial intelligence* dengan metode *support vector machine* (SVM). Tujuan dari penelitian ini adalah (i) mengetahui akurasi dari penggunaan sistem kecerdasan buatan dalam memprediksi kapasitas dukung fondasi tiang, (ii) mengetahui bagaimana penyusunan *script* berbasis kecerdasan buatan menggunakan bahasa *python* dalam memprediksi kapasitas dukung fondasi tiang, (iii) mengetahui parameter optimasi yang dapat digunakan dalam memprediksi kapasitas dukung fondasi, (iv) mengetahui pengaruh perubahan perbandingan data *training* dan data *testing* terhadap akurasi model dalam memprediksi kapasitas dukung fondasi. *Input* yang digunakan dalam pemodelan diperoleh dari pengujian *cone penetration test* (CPT) dan karakter fondasi yang akan digunakan. Sedangkan data validasi dan kalibrasi diperoleh dari pengujian *loading test*. Data kemudian dibagi secara acak menjadi data *training* dan *testing*. Setelah itu data *training* dibagi lagi menjadi data untuk membuat model dan validasi model. Metode yang digunakan untuk memperoleh model terbaik yaitu *k-fold cross validation*. Keakuratan hasil prediksi pada proses validasi diukur dengan menggunakan nilai R^2 dan *RMSE*.

Kapasitas Dukung Fondasi

Pendekatan yang digunakan dalam memprediksi kapasitas dukung tanah di antaranya adalah pendekatan statis dan dinamis. Pendekatan statis dilakukan dengan mempelajari sifat-sifat teknis tanah. Sedangkan pendekatan dinamis dilakukan dengan menganalisis daya dukung fondasi dengan data yang diperoleh dari data pemancangan tiang. Menurut Hardiyatmo (2010) perlu dilakukan pengujian tiang untuk memvalidasi lagi hasil pendekatan tersebut. Kapasitas dukung fondasi dapat dihitung berdasarkan hasil pengujian sondir (CPT), pengujian SPT, dan data kalendering (Simalango, 2016). Menurut Iyad Alkroosh & Nikraz (2012) faktor yang mempengaruhi besar kapasitas dukung fondasi antara lain:

1. Tahanan Konus (q_c) dan Tahanan Gesek (f_s)

Tahanan konus dan tahanan gesek merupakan luaran dari pengujian CPT. q_c adalah nilai perlawanan tanah terhadap ujung konus yang dinyatakan dalam gaya per satuan luas. Sedangkan f_s adalah nilai perlawanan gesekan tanah terhadap selubung bikonus yang dinyatakan dalam gaya per satuan luas.

2. Panjang Tiang (L) dan Diameter Tiang (D)

Panjang dan diameter tiang berpengaruh pada nilai gaya gesek tiang di sekitarnya dan nilai tahanan ujung fondasi.

3. Material Tiang (*pile material*)

Material tiang dinilai memiliki pengaruh terhadap besar kapasitas dukung tiang karena setiap material yang digunakan memiliki karakteristik dan kekuatan yang berbeda.

4. Metode Instalasi (*installation method*)

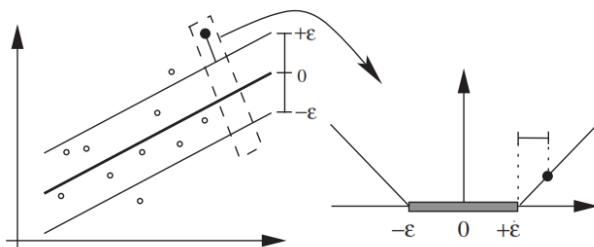
Metode instalasi tiang berpengaruh pada besar kapasitas dukung tiang, karena perpindahan tanah yang terjadi pada saat pemasangan tiang tergantung dari metode yang digunakan.

5. Jenis Penampang Tiang (*pile type*)

Jenis penampang tiang akan memengaruhi luasan dari penampang tiang. Hal ini akan berpengaruh pada tahanan ujung dan tahanan gesek tiang.

Support Vector Machine (SVM)

Support Vector Machine (SVM) adalah salah satu metode *artificial intelligence*, yang merupakan aplikasi dari algoritma berdasarkan teori statistik dan optimasi. Cara kerja SVM adalah membagi data ke dalam dua kelas atau lebih, kemudian memisahkannya dengan sebuah garis bantu yang disebut dengan *hyper-plane* seperti diilustrasikan pada Gambar 1 (Tinoco et al., 2014). SVM dapat digunakan untuk klasifikasi, regresi, dan deteksi *outliers*. Parameter optimasi yang digunakan pada metode SVM adalah kernel, C dan γ . Kernel merupakan algoritma pada SVM yang menggunakan fungsi matematika. C adalah angka yang menunjukkan *error penalty* dari model SVM. Sedangkan γ yang disebut *scale* akan menyebabkan akurasi model menurun apabila nilainya semakin tinggi dan akan menyebabkan akurasi model meningkat apabila nilainya semakin kecil.



Gambar 1. Contoh *linear SVM regression* dan the ϵ -insensitive loss function (Tinoco et al., 2014)

Koefisien Determinasi (R^2)

Koefisien determinasi (R^2) merupakan metode yang digunakan untuk mengukur seberapa jauh kemampuan model menjelaskan variasi variabel. Apabila nilai dari koefisien determinasi tinggi, artinya semakin baik kemampuan variabel bebas menjelaskan variabel terikat (Suwati, 2013).

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

Keterangan :

y_i = nilai aktual

\hat{y}_i = nilai prediksi

\bar{y} = nilai rata-rata

Root Mean Square Error (RMSE)

RMSE merupakan metode untuk mengukur besar tingkat kesalahan hasil prediksi. Apabila nilai RMSE kecil maka hasil prediksi semakin akurat (Suprayogi et al., 2014).

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

Keterangan :

n = jumlah data

Q_{uact} = kapasitas dukung fondasi aktual (kN)

Q_{usVM} = kapasitas dukung fondasi prediksi SVM (kN)

Python

Python merupakan salah satu bahasa pemrograman yang didukung dengan pustaka (*library*) dan *toolbox* yang luas, sehingga dapat membantu dalam proses klasterisasi data dan mempresentasikan grafik. Python juga termasuk ke dalam sarana pemrograman yang *open source*.

Scikit-Learn

Scikit-Learn merupakan pustaka (*library*) yang digunakan untuk pengimplementasian algoritma *machine learning*. Modul ini bertujuan untuk menjembatani kesenjangan antara penelitian *machine learning* dan aplikasi (Varoquaux et al., 2015).

METODE

Pengumpulan Data

Data dikumpulkan dari beberapa literatur yaitu 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), Mayne & Harris (1993), Nevels & Snethen (1994), Niazi & Mayne (2010), O'Neill (1986), Reese et al. (1988), Robertson et al. (1988), Shackelford (1995), Tucker & Briaud (1988), Tumay & Fakhroo (1981), Viergever (1982), Weber (1987), Yen et al. (1989), Ebrahimian (2011) dalam Ebrahimian & Movahed (2017) serta data dari Alsamman (1995) dan Eslami & Fellenius (1997) dalam I. Alkroosh & Nikraz (2011). Data yang diperoleh berupa data hasil uji CPT, data dimensi

tiang, dan data hasil *loading test*. Data hasil *loading test* akan digunakan sebagai data validasi dan kalibrasi. Parameter yang digunakan sebagai *input* dalam penelitian ini antara lain tahanan konus (q_c), tahanan gesek (f_s), panjang tiang (L), diameter tiang (D), material tiang (*pile material*), metode instalasi (*installation method*), jenis penampang tiang (*pile type*). Nilai tahanan konus (q_c) diperoleh berdasarkan teori Eslami dan Fellenius (1997). Nilai tahanan konus (q_c) pada penelitian ini adalah rata-rata resistensi ujung kerucut di atas zona pengaruh (4D di bawah kaki tiang hingga 8D di atasnya ketika tiang melewati tanah yang lemah ke padat dan padat ke tanah lemah). Sedangkan tahanan gesek (f_s) pada penelitian ini merupakan rata-rata nilai tahanan gesek pada seluruh panjang tiang yang tertanam sebagai zona pengaruh. Data dimensi tiang diperoleh dari pengukuran pada tiang. Pada tiang non lingkaran, diameter yang digunakan merupakan diameter lingkaran dengan luas penampang sama dengan luas penampang tiang.

Penyusunan *Script Python*

Script disusun untuk memprediksi kapasitas dukung fondasi dengan bahasa python. Penyusunan *script* menggunakan *text editor jupyter notebook* dan menggunakan pustaka (*library*) *Scikit-Learn*. Tahap pertama penyusunan *script* adalah *preprocessing data*. Data set yang telah dimasukkan dalam program selanjutnya dikelompokkan ke dalam suatu variabel sebagai *input* dan *output*. *Features* yang akan menjadi *input* dikelompokkan dalam suatu variabel yang bernama X. Sedangkan *features* yang akan menjadi *output* dikelompokkan ke dalam variabel yang bernama y. Parameter yang menjadi *input* adalah diameter tiang (D), panjang tiang (L), *pile material*, *pile type*, *installation method*, nilai q_c dan f_s yang diperoleh dari pengujian *cone penetration test* (CPT) dan karakter pondasi tiang yang akan digunakan. *Output* dari model ini adalah Q_r . Setelah itu data dibagi menjadi data *training* dan data *testing*. Besar proporsi data *testing* divariasikan sebesar 10%, 20%, 30% dan 40% dari total data. Data *testing* akan digunakan sebagai data pada proses *final test*. Sedangkan data *training* juga akan digunakan pada proses pembuatan model dan validasi model menggunakan metode *k-fold cross validation*. Proses selanjutnya yaitu penentuan parameter optimasi pada model. Parameter optimasi yang digunakan pada model SVM adalah kernel, C, dan γ . Kernel yang digunakan pada tahap awal pemilihan kernel terbaik adalah *linear*, *polynomial*, dan *radial basis function* (RBF). Sedangkan untuk menentukan parameter C dan γ yang optimum, maka digunakan variasi C dan γ 0,5 ; 5,0 ; 50,0 ; 500,0 dan 0,001 ; 0,01 ; 0,1; secara berturut-turut. Setelah mendapatkan parameter optimasi terbaik, selanjutnya dilakukan proses *final test* menggunakan data *testing*.

Validasi Hasil

Validasi hasil dilakukan untuk menemukan model dengan performa terbaik. Metode yang digunakan untuk validasi hasil adalah *10-fold cross validation*. Metode ini membagi data menjadi 10 *folds* yang berukuran kira-kira sama. Kemudian dilakukan *testing* pada 1 bagian data dan 9 bagian data sisanya digunakan sebagai *training*.

Diagram Alir Penelitian

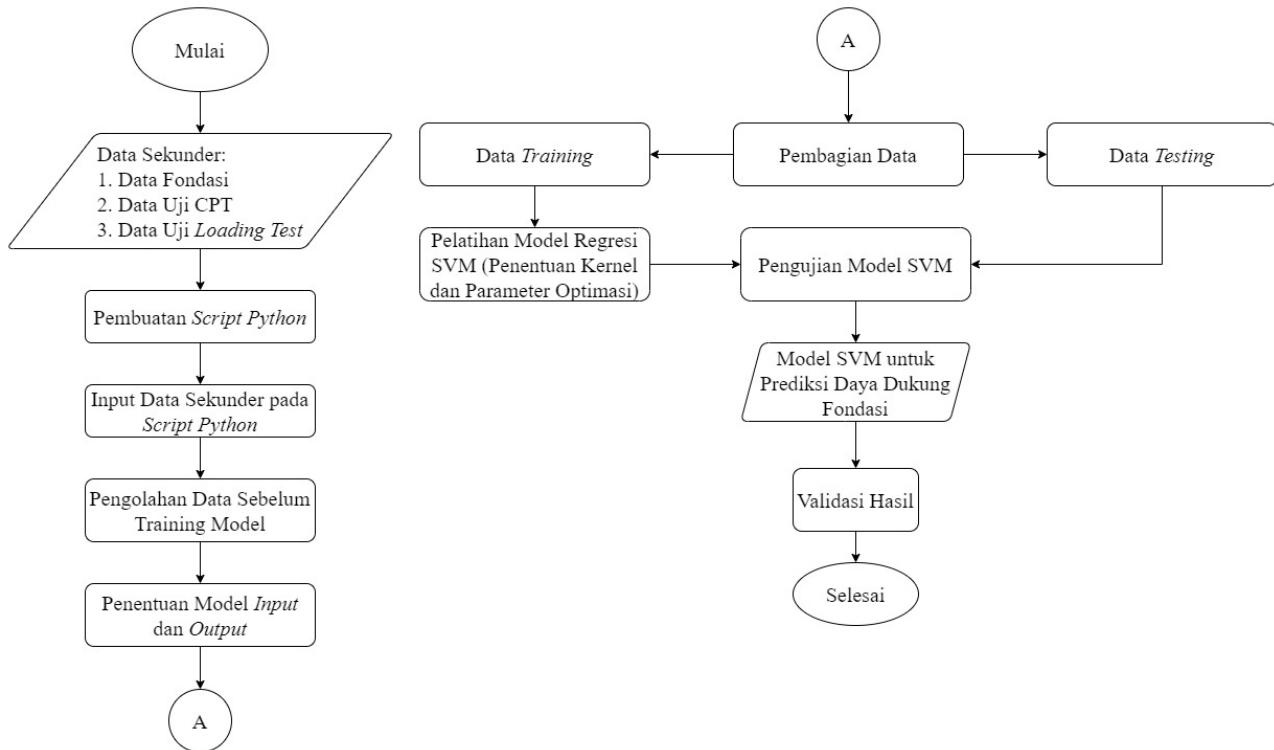
Diagram alir penelitian ini dapat dilihat pada Gambar 2. Penelitian dimulai dengan pengumpulan data. Kemudian dilanjutkan dengan proses pembuatan *script* menggunakan bahasa *python*. Setelah itu dilakukan validasi hasil untuk mendapatkan model prediksi terbaik.

HASIL DAN PEMBAHASAN

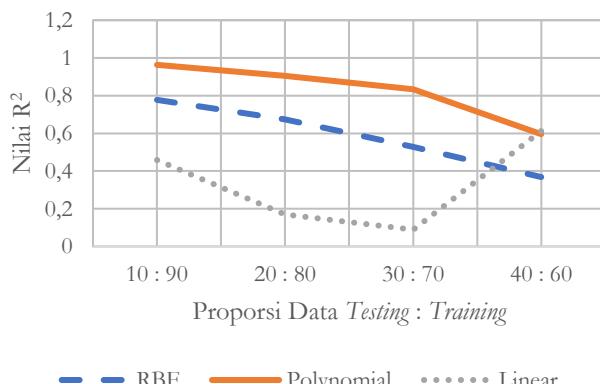
Analisis Model

1. Penentuan Kernel

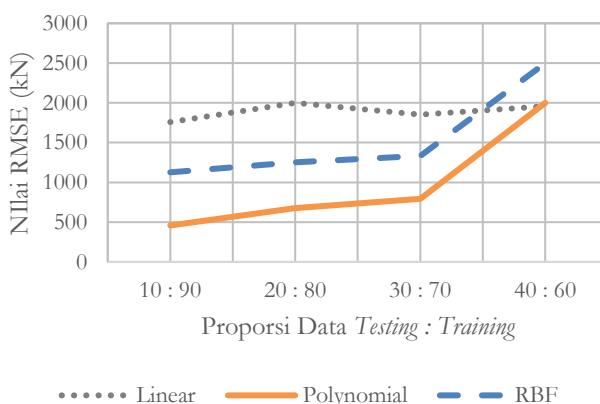
Hasil pengujian awal ditunjukkan pada Gambar 3. Gambar tersebut memperlihatkan bahwa kernel *polynomial* memiliki performa yang paling baik, ditunjukkan dengan nilai R^2 tinggi pada proporsi data *training* tinggi dan semakin menurun seiring dengan berkurangnya jumlah data *training*. Pada kernel RBF terjadi hal serupa dengan kernel *polynomial*. Akan tetapi, keakuratan kernel *polynomial* lebih tinggi dibandingkan dengan kernel RBF. Sedangkan pada kernel *linear*, performa model tidak stabil ditunjukkan dengan nilai R^2 yang kembali meningkat pada proporsi data *training* 60%. Gambar 4. menampilkan nilai RMSE hasil pengujian awal. Kernel *polynomial* terlihat memiliki nilai RMSE yang paling rendah, sehingga dari ketiga kernel tersebut, kernel *polynomial* dipilih sebagai kernel yang digunakan dalam penelitian ini dan digunakan lebih lanjut untuk mencari kondisi optimum dari parameter C dan γ .



Gambar 2. Diagram alir penelitian



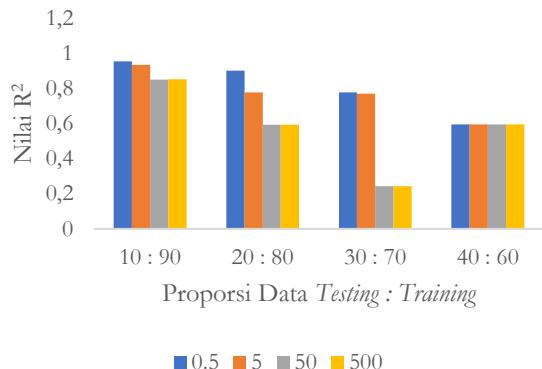
Gambar 3. Grafik perbandingan proporsi data *testing-training* dengan nilai R^2 untuk setiap jenis kernel SVM



Gambar 4. Grafik perbandingan proporsi data *testing-training* dengan nilai RMSE untuk setiap jenis kernel SVM

2. Penentuan Parameter C

Gambar 5 dan Gambar 6 merupakan hasil pelatihan model yang menunjukkan bahwa pada setiap proporsi data training, nilai C dengan performa terbaik adalah 0,5. Sedangkan nilai C lain tidak dapat mempertahankan performanya seiring dengan berkurangnya jumlah data training. Sehingga dapat disimpulkan bahwa nilai C terbaik yang dapat digunakan pada model adalah 0,5.



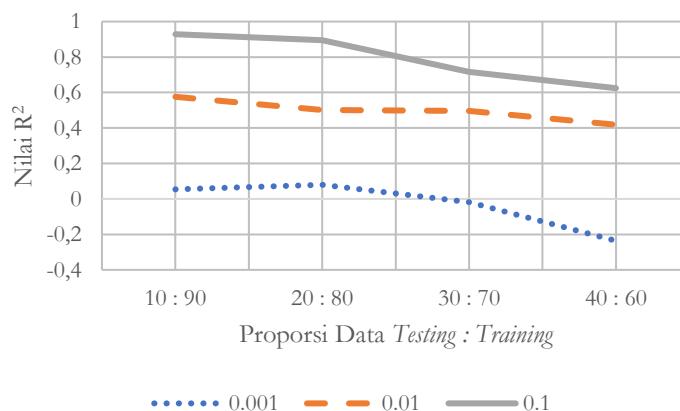
Gambar 5. Nilai R^2 pada perubahan nilai C



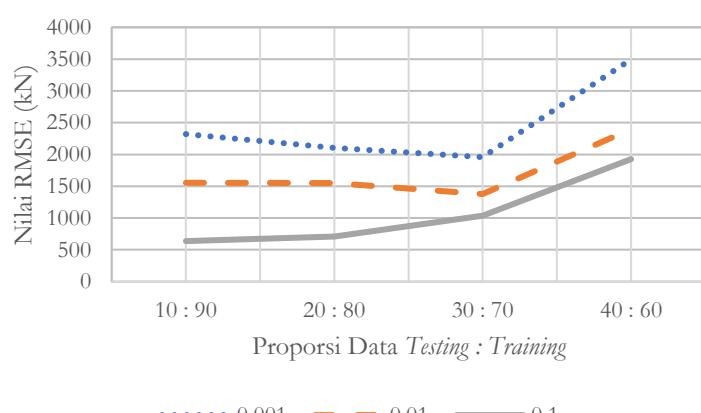
Gambar 6. Nilai RMSE pada perubahan nilai C

3. Penentuan Parameter γ

Hasil pelatihan model untuk menentukan parameter γ dapat dilihat pada Gambar 7. dan Gambar 8. Grafik menunjukkan bahwa pada setiap proporsi data *training*, nilai γ dengan performa terbaik adalah 0,1 yang ditunjukkan dengan nilai R^2 tertinggi dan RMSE terendah di antara nilai γ lainnya. Sehingga dapat disimpulkan bahwa nilai γ terbaik yang dapat digunakan pada model adalah 0,1.



Gambar 7. Nilai R^2 pada perubahan nilai γ



Gambar 8. Nilai RMSE pada perubahan nilai γ

4. Validasi Hasil

Tabel 1. menunjukkan nilai R^2 dan RMSE dari pengujian performa model. Model dengan nilai *cross validation* terbaik adalah model dengan kernel *polynomial* serta parameter $C = 0,5$ dan $\gamma = 0,1$ dengan nilai $R^2 = 0,5512$ dan RMSE = 1965,7059 kN. Parameter tersebut bekerja dengan baik pada perbandingan data *training* = 90% dan *testing* = 10%.

Tabel 1. Validasi hasil

Perbandingan <i>testing : training (%)</i>	γ	R^2	RMSE (kN)	<i>Cross Validation Score (R²)</i>	<i>Cross Validation Score (RMSE)</i>
10 : 90	0,001	0,0531	2322,2414	-0,2525	332,9789
	0,01	0,5756	1554,6637	0,3627	1295,0423
	0,1	0,9287	637,1087	0,5512	1965,7059
20 : 80	0,001	0,0796	2105,2518	-0,4919	417,0790
	0,01	0,5019	1548,8095	0,2028	1349,2071
	0,1	0,8951	710,7111	0,4646	1980,0111
30 : 70	0,001	-0,0176	1957,6775	-0,2983	216,2778
	0,01	0,4966	1376,9099	0,2919	1221,6942
	0,1	0,7162	1033,8301	0,3822	1916,7092
40 : 60	0,001	-0,2364	3495,1444	-1,2097	473,1893
	0,01	0,4183	2397,3827	0,0225	1036,2355
	0,1	0,6244	1926,3723	0,2797	1169,1820

SIMPULAN

Model *machine learning* metode SVM yang memiliki performa terbaik adalah model yang menggunakan kernel *polynomial*, dengan pengaturan parameter $C = 0,5$ dan $\gamma = 0,1$; hal ini ditunjukkan dengan nilai R^2 mencapai 0,9287 dan RMSE 637,1087 kN pada proses *testing*. Sedangkan pada proses *cross validation*, nilai R^2 mencapai 0,5512.

UCAPAN TERIMAKASIH

Terima kasih kepada Tuhan Yang Maha Esa atas limpahan rahmat dan nikmat-Nya sehingga penulis dapat menyelesaikan penelitian ini dengan baik. Ucapan terima kasih penulis untuk orang tua dan sahabat yang selalu memberi semangat serta doa. Terima kasih juga penulis sampaikan kepada kelompok penelitian penulis yang sangat mendukung dan membantu penulis 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*, 29(5), 725–748. <https://doi.org/10.1007/s10706-011-9413-1>
- Alkroosh, Iyad, & Nikraz, H. (2012). Predicting axial capacity of driven piles in cohesive soils using intelligent computing. *Engineering Applications of Artificial Intelligence*, 25(3), 618–627. <https://doi.org/10.1016/j.engappai.2011.08.009>
- 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*, 29(1), 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. *Proc. Int. Conf. on Design and Construction of Deep Foundations, FHWA*, 712–723.
- 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>
- Eslami, A., & Fellenius, B. H. (1997). Pile capacity by direct CPT and CPTu methods applied to 102 case histories. *Canadian Geotechnical Journal*, 34(6), 886–904. <https://doi.org/10.1139/t97-056>
- Gambini, F. (1985). Experience in Italy with centricast concrete piles. *Proc. Int. Symp. on Penetrability and Drivability of Piles*, 97–100.
- Hardiyatmo, H. C. (2010). Analisis dan Perancangan Fondasi. In H. C. Hardiyatmo (Ed.), *Analisis dan Perancangan Fondasi* (3rd ed.). Gadjah Mada University 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. E., Stettler, D. R., & Crowser, J. C. (1981). Comparison of predicted and observed pile capacity. *Cone Penetration Testing and Experience*, 413–433.
- 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. E. (1994). Predicting the ultimate compressive capacity of long 12-H-74 steel pile. *Proc. Int. Conf. on Design and Construction of Deep Foundations*, 1804–1818.
- Mayne, P. W., & Harris, D. E. (1993). ‘Axial Load-Displacement Behavior of Drilled Shaft Foundations in Piedmont Residuum. *FHWA Reference No. 41-30*, 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*, 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. *Use of In Situ Tests in Geotechnical Engineering*, 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. *Lyman C. Reese and Associates, Austin, Tex.*
- 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*. 1, 919–927.
- Shackelford, C. D. (1995). Cumulative mass approach for column testing. *Journal of Geotechnical Engineering*, 121(10), 696–703.
- SIMALANGO, A. (2016). Analisis Daya Dukung Dan Penurunan Pondasi Tiang Pancang Dengan Metode Analitis Dan Metode Elemen Hingga Pada Bore Hole II (Study Kasus Pembangunan Bendung Bajayu Sei Padang Kabupaten Serdang Bedagai Sumatera Utara). *Jurnal Teknik Sipil USU*.
- Suprayogi, I., Trimajon, & Mahyudin. (2014). Model Prediksi Liku Kalibrasi Menggunakan Pendekatan Jaringan Saraf Tiruan (ZST) (Studi Kasus : Sub DAS Siak Hulu). *Jurnal Online Mahasiswa Fakultas Teknik Universitas Riau*, 1(1), 1–18.
- Suwati, Y. (2013). Pengaruh Kompensasi Dan Motivasi Kerja Terhadap Kinerja Karyawan Pada Pt. Tunas Hijau Samarinda. *EJournal Ilmu Administrasi Bisnis*, 1(1), 41–55.
- Tinoco, J., Gomes Correia, A., & Cortez, P. (2014). Support vector machines applied to uniaxial compressive strength prediction of jet grouting columns. *Computers and Geotechnics*, 55, 132–140. <https://doi.org/10.1016/j.compgeo.2013.08.010>
- 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. *Cone Penetration Testing and Experience*, 434–455.
- Varoquaux, G., Buitinck, L., Louppe, G., Grisel, O., Pedregosa, F., & Mueller, A. (2015). *Varoquaux2015*. 19(1), 29–33.
- 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. F. (1989). Interpretation of instrumented driven steel pipe piles. *Proc. Foundation Eng. Cong.: Current Principle and Practices*, GSP No, 22, 1293–1308.