

Prediksi Nilai SPT Tanah Granular Berdasarkan Data CPT dan Properties Tanah di Sumatera Menggunakan Jaringan Saraf Tiruan

Soewignjo Agus Nugroho^(*)

Universitas Riau, Jl. HR. Subrantas KM 12,5, Pekanbaru, Riau,
E-mail: soewignjo.nugroho@lecturer.unri.ac.id

Hendra Fernando

Universitas Riau, Jl. HR. Subrantas KM 12,5, Pekanbaru, Riau,
E-mail: hhendra.fernandoo@gmail.com

Reni Suryanita

Universitas Riau, Jl. HR. Subrantas KM 12,5, Pekanbaru, Riau,
E-mail: reni.suryanita@lecturer.unri.ac.id

Abstrak

Standard Penetration Test (SPT) dan Cone Penetration Test (CPT) merupakan tes penyelidikan tanah awal yang sering digunakan saat memulai suatu konstruksi. Telah banyak penelitian sebelumnya yang membahas tentang korelasi linier antara nilai SPT dan CPT, namun nilai koefisien korelasinya (R^2) cenderung kecil. Jaringan saraf tiruan (JST) merupakan teknik yang dapat memecahkan masalah yang kompleks dan non-linier. Pada penelitian ini akan dilakukan prediksi nilai SPT menggunakan jaringan saraf tiruan pada tanah granular menggunakan algoritma backpropagation. Penelitian ini menggunakan 117 data dari beberapa wilayah di Provinsi Riau. Data masukan yang digunakan berupa nilai tahanan ujung (q_c) dan nilai tahanan selimut (f_s) dari pengujian CPT dan nilai tekanan overburden efektif (σ'_0) serta persentase pasir dan butiran halus. JST dianggap efektif dalam penelitian ini dengan nilai RMSE 3,646, MAE 2,533 dan R^2 0,9103 untuk data latih dan RMSE 2,955, MAE 2,190, R^2 0,9311 untuk data uji. Selanjutnya model JST ini disebut sebagai NN_Nspt (NC).

Kata-kata Kunci: back-propagation, CPT, granular, Jaringan Saraf Tiruan, SPT

Abstract

The Standard Penetration Test (SPT) and the Cone Penetration Test (CPT) are kinds of Soil Investigation Tests that are used to determine bearing capacity and soil parameters for designing a construction. There are many previous studies had been defined the linear correlation between SPT and CPT values. However, the linear correlation predisposed get correlation coefficient (R^2) small. Artificial neural networks (ANN) is an Artificial Intelligence model that can solve complex and non-linear problems. This research aims to conduct SPT value prediction using ANN in granular soil (non-cohesive) with a backpropagation algorithm function. This study used 117 data taken from several provinces on Sumatera island. The variables of input data are taken from CPT, i.e cone resistance (q_c) and sleeve resistance (f_s), and from the UDS test. The laboratory data were effective overburden pressure (σ'_0), the percentage of sand, and the percentage of fine grain. The best ANN model had a single hidden layer and 40 neurons with RMSE values 3.646, MAE 2.533, and R^2 0.9103 for training data and RMSE 2.955, MAE 2.190, R^2 0.9311 for testing data. Thus, the best ANN model has been proposed as NN_Nspt (NC).

Keywords: Artificial Neuron Network, back-propagation, CPT, granular, SPT

1. Pendahuluan

Penyelidikan tanah merupakan langkah awal dalam memulai sebuah konstruksi. Penyelidikan awal tanah di lapangan biasanya menggunakan Standard Penetration Test (SPT) dan Cone Penetration Test (CPT). Selain itu, juga dilakukan penyelidikan tanah di laboratorium yang bertujuan untuk mendapatkan informasi lebih lanjut tentang tanah. Penyelidikan tanah di lapangan dan laboratorium bertujuan untuk mendapatkan

parameter sifat fisik dan mekanik tanah yang akan berguna dalam analisis dan desain pondasi. Selain itu, data yang diperoleh dapat digunakan sebagai pembandingan, khususnya untuk penyelidikan tanah sejenis. Nilai SPT menunjukkan adanya korelasi dengan nilai CPT (pengujian Sondir) dan sifat fisik tanah lainnya. Hubungan ini telah banyak dipelajari oleh para peneliti sebelumnya. Pada **Tabel 1** di bawah ini, terdapat beberapa korelasi antara nilai SPT, CPT dan sifat fisik tanah oleh beberapa peneliti terdahulu. Hubungan ini menggunakan parameter K_c , dimana K_c

^{*}Penulis Korespondensi

Tabel 1. Korelasi nilai SPT berdasarkan penelitian terdahulu

Referensi	Kc (Mpa)	Notes
Akca (2003)	0.77	Pasir
	0.70	Pasir berlanau
	0.58	Lanau berpasir
Mayne (2006)	0.438	Pasir (Kanada, Jepang, Norwegia, China dan Italia): D50 = 0.35+/-0.23 mm
Ahmed et al. (2014)	0.508	Pasir bersih dan lanau berpasir, FC =3% - 35%
Shahri et al. (2014)	0.568	Pasir Sweden
	0.367	Lempung, Lempung berlanau dan lanau
	0.423	Lanau berpasir, lanau-pasir
	0.529	Pasir halus dan Pasir berlempung
	0.374	Lempung berpasir, pasir berlanau, pasir berlempung berlanau,
	0.572	Pasir berkerikil, pasir kasar dan pasir-kerikil
Lingwanda et al. (2015)	0.37	Lempung dan pasir berlanau (Tanzania) : D50 = 0.38 mm
dos Santos & Bicalho (2017)	0.43	Pasir Victoria
	0.427	Pasir Berlanau
	0.337	Lanau Berpasir
Alam et al. (2018)	0.319	Lempung Berlanau
	0.291	Lempung

adalah rasio antara q_c dan N-SPT atau $K_c = q_c / NSPT$ (dalam Mpa), D50 adalah diameter butir yang melewati saringan 50% dan FC adalah kandungan butiran halus (Nugroho et al., 2021)

Korelasi ini cenderung linier sedangkan pada umumnya tanah dari satu tempat ke tempat lain memiliki sifat yang bervariasi dengan ketidakpastian yang besar, hal ini disebabkan oleh formasi tanah yang sangat kompleks (Jaksa, 1995). Karena sifat tanah yang kompleks dan nonlinier maka diperlukan suatu inovasi dalam menentukan nilai SPT yang lebih efektif dan dapat menyelesaikan persamaan kompleks formasi tanah sehingga nantinya diharapkan suatu model dapat memprediksi nilai SPT dengan nilai error yang kecil.

Pada penelitian ini akan dilakukan prediksi nilai SPT menggunakan jaringan saraf tiruan. Jaringan saraf tiruan dipilih dalam penelitian ini karena Jaringan Saraf Tiruan (JST) dapat menyelesaikan masalah yang kompleks dan nonlinier. JST merupakan sistem komputasi yang arsitektur dan operasinya diinspirasi oleh pengetahuan biologis sel saraf di otak, yang merupakan salah satu representasi buatan dari otak manusia yang selalu berusaha untuk merangsang proses pembelajaran di otak manusia. JST juga dapat diartikan sebagai model komputer skala kecil dari otak manusia yang dapat dilatih dengan kecepatan tinggi untuk berbagai masalah nonlinier dengan menggunakan algoritma pengarsipan yang sesuai (Ghaderi et al., 2019). Arsitektur JST terdiri dari 3 lapisan utama, yang pertama adalah lapisan masukan dimana unit-unit ini merepresentasikan nilai suatu pola

sebagai masukan jaringan. Yang kedua adalah lapisan tengah atau biasa disebut lapisan tersembunyi yang merespons properti tertentu yang mungkin terlihat dalam pola masukan. Terkadang ada lebih dari satu lapisan tersembunyi di jaringan. Lapisan terakhir adalah lapisan keluaran, yang berfungsi sebagai saluran keluar untuk jaringan saraf tiruan. Algoritma pembelajaran yang paling sering digunakan oleh para peneliti khususnya di bidang rekayasa geoteknik adalah algoritma *Backpropagation*.

Hingga saat ini JST masih menjadi inovasi bagi para peneliti dalam menyelesaikan permasalahan yang kompleks, khususnya di bidang geoteknik. Beberapa penelitian sebelumnya yang menggunakan menggunakan jaringan saraf tiruan ini seperti penentuan daya dukung tiang pancang (Kurup & Griffin, 2006), perilaku fondasi dangkal seperti perkiraan penurunan (Chen et al., 2006; M. A. Shahin et al., 2005) dan daya dukung (Kuo et al., 2009; Padmini et al., 2008), likuifaksi (Goh, 2002), stabilitas lereng (Zhao, 2008) dan banyak studi terkait lainnya.

Penelitian tentang prediksi nilai SPT juga telah banyak dilakukan oleh peneliti sebelumnya. Penelitian terkait yang telah dilakukan sebelumnya, seperti prediksi N-SPT berdasarkan data CPT dengan lokasi penelitian di Dubai dan Abu Dhabi, Uni Emirat Arab (Tarawneh, 2017) dimana hasil penelitian diperoleh nilai $R = 0.95$ dan $MAE = 2.88$. Penelitian serupa juga telah dilakukan dengan lokasi penelitian di Izmir, Turki dengan masukan data berupa persentase kerikil, pasir, lanau dan lempung (Erzin & Tuskan, 2017) dengan

hasil penelitian nilai R^2 pada pelatihan 0,9738 dan R^2 pada pengujian 0,9348, MAE pada pelatihan 0,01 dan MAE pada pengujian 0,05 dan nilai RMSE pada pelatihan 0,04 dan pada pengujian 0,08. R^2 , RMSE dan MAE merupakan tolok ukur dalam menentukan keakuratan suatu persamaan atau ramalan. Semakin kecil nilai RMSE dan MAE menunjukkan tingkat akurasi yang lebih tinggi, sedangkan nilai R^2 yang mendekati 1 menunjukkan tingkat akurasi yang baik.

2. Metodologi

Data set berupa data hasil pengujian di lapangan (CPT, SPT) dan pengujian di laboratorium (sampel UDS). Pengelompokan data sesuai dengan kedalaman penyelidikan tanah yang sama di suatu lokasi. Data-data q_c , f_s , kadar air, berat volume merupakan variabel input dengan input berupa nilai SPT (Nugroho et al., 2021). Data input dan output dimasukkan dalam jaringan saraf tiruan (aplikasi Matlab) untuk mendapatkan model terbaik. Secara umum prosedur penelitian dapat dilihat pada **Gambar 1** berikut ini:


2.1 Pengumpulan data

Pengumpulan data merupakan suatu kegiatan yang bertujuan untuk mencari data yang dibutuhkan dalam proses penelitian guna mencapai tujuan penelitian. Dalam penelitian ini data yang dibutuhkan adalah data hasil SPT, CPT (sondir) dan uji laboratorium. Dalam pengujian SPT, data yang dibutuhkan adalah nilai SPT.

Pada pengujian Sondir, data yang dibutuhkan adalah nilai tahanan ujung (q_c) dan tahanan selimut (f_s). Dalam pengujian laboratorium, data yang dibutuhkan adalah nilai tekanan overburden efektif (σ'_0), persentase pasir dan butiran halus. Data tersebut diperoleh dari Laboratorium Mekanika Tanah Fakultas Teknik Universitas Riau. Data yang diperoleh merupakan hasil pengujian di beberapa wilayah di Pulau Sumatera, diantaranya Provinsi Riau, Kepulauan Riau, Sumatera Utara, Sumatera Barat, Sumatera Selatan dan Jambi dari tahun 2005 hingga 2020. Statistik semua data dapat dilihat pada **Tabel 2** di bawah (Fernando et al., 2021).

2.2 Normalisasi data

Pada penelitian ini akan dikembangkan jaringan saraf tiruan dengan algoritma *back-propagation*. Pada algoritma *backpropagation* fungsi aktivasi yang digunakan harus memenuhi beberapa kriteria yaitu: kontinyu, mudah dibedakan dan fungsi yang tidak turun. Fungsi aktivasi yang sering digunakan adalah fungsi *sigmoid biner* yang mempunyai range 0 sampai 1 dan fungsi aktivasi *sigmoid bipolar* yang mempunyai range -1 sampai 1. Fungsi tersebut akan membawa kisaran nilai masukan yang tak terhingga ke keluaran yang berhingga nilai. Untuk membawa kisaran nilai keluaran ke dalam kisaran masukan, data masukan harus dinormalisasi, yaitu mengubah data menjadi kisaran fungsi aktivasinya (Nugroho et al., 2022). Pada penelitian ini akan dilakukan penelitian dengan menggunakan fungsi aktivasi *sigmoid bipolar*,



Gambar 1. Bagan alir metodologi

Tabel 2. Statistik data yang dikumpulkan

Variable	q_c (kPa)	f_s (kPa)	(σ'_0) (kPa)	Sand (%)	Fines (%)	N-SPT (blows/ft)
Max	24525	274.68	467.28	99.9	50.46	59
Min	196.2	9.81	28.305	49.54	0.1	1
Mean	7088.052	109.697	162.967	91.583	8.417	18.257
SD	5204.652	66.813	97.187	11.739	11.739	12.228

kemudian datanya akan dinormalisasi dengan mentransformasikan data tersebut menjadi range -1 sampai 1. Rumus yang digunakan adalah metode normalisasi min-max dengan menggunakan **Persamaan (1)** sebagai berikut:

$$X_{normalization} = \frac{X_{current} - ((X_{max} + X_{min})/2)}{(X_{max} - X_{min})/2} \quad (1)$$

2.3 Pelatihan dan pengujian data

Pembuatan model jaringan saraf tiruan dilakukan dengan membagi data menjadi dua bagian yaitu sebagai data latih dan sebagai data uji. Data latih merupakan data yang akan digunakan untuk melatih jaringan, sedangkan data uji merupakan data yang belum pernah digunakan dalam pelatihan jaringan dan bertujuan untuk menilai kinerja suatu jaringan. Dalam penelitian ini terdapat 117 data dimana 80% data akan digunakan sebagai data latih (training data) dan 20% data sebagai data uji (testing data).

2.4 Perancangan model jaringan saraf tiruan

Rancangan arsitektur model jaringan saraf tiruan yang akan dikembangkan disesuaikan dengan aplikasi yang akan dikembangkan. Untuk memprediksi nilai SPT yang membutuhkan data masukan yang relatif besar, diperlukan jaringan *multilayer* dengan algoritma *back-propagation* dan metode pembelajaran yang diawasi. Dengan banyaknya data yang akan digunakan dan permasalahan yang relatif kompleks yang harus

diselesaikan, maka model JST yang akan dikembangkan adalah JST dengan arsitektur jaringan multilayer yang terdiri dari 3 (tiga) lapis, yaitu:

1. *Input layer* yang terdiri dari beberapa neuron yang jumlahnya disesuaikan dengan pola masukan.
2. Satu atau lebih *hidden layer* dengan beberapa neuron yang jumlahnya dilakukan dengan *trial and error*, yang dipilih adalah yang menghasilkan konvergensi dengan jumlah iterasi (*epoch*) paling sedikit.
3. *Output layer* yang terdiri dari beberapa neuron tergantung pada pola keluaran yang diinginkan.

Selanjutnya untuk mendapatkan jaringan dengan performa terbaik dilakukan *trial and error* pada arsitektur jaringan (trial pada jumlah *hidden layer* dan jumlah neuron pada *hidden layer*). Selain itu dapat pula dilakukan trial pada fungsi aktivasi (sigmoig bipolar/fungsi *tansig* atau *sigmoid biner*/fungsi *logsig*) dan uji coba pada fungsi pelatihan (*Trainlm*, *traincgb*, *traincgp*, *traincgf*, *trainrp*, *traingdx*, *traingda*, *traingdm* atau *traingd*). Variasi juga dapat dilakukan dengan memvariasikan parameter pelatihan sesuai dengan fungsi pelatihan yang digunakan (*epoch*, *learning rate*, *goal*, dll.)

Sebagai contoh, berikut adalah trial yang dilakukan dengan proses variasi sesuai dengan yang telah dijelaskan sebelumnya.

• Model i (*Trainlm*_1HL_5N) :

Fungsi aktivasi	=	<i>Tansig</i>
Fungsi pelatihan	=	<i>Trainlm</i>
Lapisan tersembunyi	=	1
Neuron Lapisan Tersembunyi	=	5

• Model i (*Trainlm*_1HL_10N) :

Fungsi aktivasi	=	<i>Tansig</i>
Fungsi pelatihan	=	<i>Trainlm</i>
Lapisan tersembunyi	=	1
Neuron Lapisan Tersembunyi	=	10

Jika menggunakan 1 *hidden layer* belum mendapatkan jaringan performa terbaik, variasi dapat dilakukan dengan menambah jumlah *hidden layer*.

• Model i (*Trainlm*_2HL_5N(HL1)_5(HL2))

Fungsi aktivasi	=	<i>Tansig</i>
Fungsi pelatihan	=	<i>Trainlm</i>
Lapisan tersembunyi	=	2
Neuron Lapisan Tersembunyi 1	=	5
Neuron Lapisan Tersembunyi 2	=	5

• Model i (*Trainlm*_2HL_5N(HL1)_10N(HL2))

Fungsi aktivasi	=	<i>Tansig</i>
Fungsi pelatihan	=	<i>Trainlm</i>
Lapisan tersembunyi	=	2
Neuron Lapisan Tersembunyi 1	=	5
Neuron Lapisan Tersembunyi 2	=	10

Jika menggunakan fungsi pelatihan *Trainlm* belum mendapatkan jaringan dengan kinerja terbaik, selanjutnya dapat dilakukan variasi dengan mengganti fungsi pelatihan lainnya.

• Model i (*traincgb*_1HL_5N) :

Fungsi aktivasi	=	<i>Tansig</i>
Fungsi Pelatihan	=	<i>Traincgb</i>
Lapisan tersembunyi	=	1
Neuron Lapisan Tersembunyi	=	5

• Model i (*traincgb*_1HL_10N) :

Fungsi aktivasi	=	<i>Tansig</i>
Fungsi Pelatihan	=	<i>Traincgb</i>
Lapisan tersembunyi	=	1
Neuron Lapisan Tersembunyi	=	10

Jika menggunakan fungsi aktivasi *sigmoid bipolar* belum mendapatkan jaringan kinerja terbaik, maka dapat dilanjutkan dengan memvariasikannya menjadi fungsi aktivasi *sigmoid biner*. Proses pelatihan dapat dihentikan jika telah memperoleh jaringan dengan nilai MSE kecil dan R yang mendekati 1.

2.5 Pengujian model jaringan saraf tiruan

Pengujian model jaringan yang telah dikembangkan bertujuan untuk mengukur ketepatan atau kinerja model jaringan dalam memprediksi nilai keluaran yang kemudian dibandingkan dengan nilai aslinya. Tolak ukur yang digunakan dalam menilai akurasi dalam penelitian ini adalah nilai RMSE dan MAE. Suatu persamaan dikatakan memiliki akurasi yang baik jika memiliki nilai RMSE dan MAE yang kecil. Rumus yang digunakan dalam menghitung RMSE dan MAE dapat dilihat pada Persamaan (2) dan Persamaan (3) berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - y_i)^2} \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| \quad (3)$$


Dimana RMSE adalah *Root Mean Square Error*, MAE adalah *Mean Absolute Error*, f_i adalah nilai asli, y_i adalah nilai hasil prediksi, n adalah jumlah data.

3. Hasil dan Kesimpulan

3.1 Hasil tahap pembuatan model

Arsitektur jaringan dilakukan dengan cara trial and error jumlah hidden layer, neuron, dan fungsi aktivasi pada model JST. Model terbaik merupakan arsitektur jaringan dimana nilai R pada data training dan data uji nilainya paling mendekati 1. Pada penelitian ini didapatkan bahwa jaringan dengan performa terbaik adalah jaringan dengan arsitektur jaringan berupa 1 *hidden layer* dan 40 neuron pada *hidden layer* menggunakan fungsi aktivasi *traincgb*. Arsitektur jaringan yang telah dikembangkan dapat dilihat pada **Gambar 2**.

Perbedaan antara nilai antara output dan target pada data latih adalah kecil dimana nilai korelasinya adalah R_{training}



Gambar 2. Arsitektur jaringan NN_Nspt (NC)

$=0.94764$, $R_{\text{validation}} = 0.98962$. Pada data uji beda antara nilai output dan target juga kecil, dimana korelasi mempunyai nilai $R_{\text{Test}} = 0.93521$ dan $R_{\text{All}} = 0.94719$. Hasil regresi pada tanah non cohesive (granular), Model Regresi JST NN_Nspt (NC), dapat dilihat pada **Gambar 3**.

3.2 Bobot dan bias

Satu set data pada input layer terdiri dari 5 (lima) neuron dan jumlah neuron pada lapisan tersembunyi (hidden layer) ada 40. Neuron input layer untuk masuk ke hidden layer harus dihitung weight (bobot) dan bias masing-masing. input layer berupa matrik $(5 \times 1)_i$; matrik bobot berupa matrik (40×5) ; dan matrik bias berupa matrik $(40 \times 1)_i$ sehingga:

$$[Z_1]_{40 \times 1, (i)} = [W_1]_{40 \times 5, (i)} [I]_{5 \times 1, (i)} + [b_i]_{40 \times 1, (i)} \quad (4)$$

dimana $[W_1]$ adalah matrik bobot pada **Tabel 3** dan $[b_i]$ adalah matrik bias input sesuai **Tabel 4**.

Demikian juga neuron pada hidden layer untuk masuk lapisan output (output layer) harus diberi bobot dan bias output (WO, BO), sehingga:


$$[Y_1]_{1 \times 1, (i)} = [Z_1]_{1 \times 40, (i)} [W_2]_{40 \times 1, (i)} + [b_o]_{1 \times 1, (i)} \quad (5)$$

$[W_2]$ adalah matrik bobot output pada **Tabel 5** dan $[b_o]$ adalah matrik bias output pada **Tabel 6**.

3.3. Hasil tahap pengujian model

Pada tahap ini akan dilakukan simulasi terhadap data masukan yang ada, baik pada data latih maupun pada data uji dalam memprediksi nilai SPT. Hasil simulasi kemudian dibandingkan dengan nilai SPT asli untuk menghitung nilai RMSE dan MAE yang dapat dilihat pada **Tabel 7**. Untuk menghitung nilai RMSE dan MAE, dapat dilakukan dengan menggunakan **Persamaan (2)** dan **Persamaan (3)**. Pada **Gambar 4** dapat dilihat grafik antara nilai SPT prediksi dengan nilai SPT asli yang selanjutnya dapat ditentukan oleh nilai R^2 untuk mengukur tingkat akurasi prediksi.

Perhitungan Prediksi nilai SPT dapat dihitung secara manual dengan operasi matriks menggunakan nilai



Gambar 3. Model regresi JST NN_Nspt (NC)

Tabel 3. Bobot dari *input layer* ke hidden layer [W_i]

W_{i11}	1.616	W_{i12}	-0.888	W_{i13}	-2.009	W_{i14}	-1.006	W_{i15}	0.689
W_{i21}	0.036	W_{i22}	-1.338	W_{i23}	0.926	W_{i24}	2.573	W_{i25}	-3.015
W_{i31}	0.231	W_{i32}	-1.207	W_{i33}	1.278	W_{i34}	1.550	W_{i35}	1.181
W_{i41}	1.179	W_{i42}	-1.514	W_{i43}	-0.221	W_{i44}	-1.170	W_{i45}	1.136
W_{i51}	-1.852	W_{i52}	-1.499	W_{i53}	-1.598	W_{i54}	1.204	W_{i55}	-1.573
W_{i16}	-0.768	W_{i17}	1.654	W_{i18}	-0.438	W_{i19}	-1.396	W_{i110}	0.280
W_{i26}	1.519	W_{i27}	-1.082	W_{i28}	1.469	W_{i29}	1.819	W_{i210}	0.113
W_{i36}	-0.476	W_{i37}	1.011	W_{i38}	-1.806	W_{i39}	0.531	W_{i310}	1.983
W_{i46}	1.091	W_{i47}	1.425	W_{i48}	0.558	W_{i49}	1.187	W_{i410}	1.668
W_{i56}	1.952	W_{i57}	0.903	W_{i58}	1.724	W_{i59}	-0.887	W_{i510}	-1.208
W_{i111}	2.502	W_{i112}	1.117	W_{i113}	-0.426	W_{i114}	-1.588	W_{i115}	1.220
W_{i211}	-0.291	W_{i212}	2.529	W_{i213}	-2.364	W_{i214}	0.210	W_{i215}	0.688
W_{i311}	0.346	W_{i312}	1.307	W_{i313}	-1.091	W_{i314}	0.761	W_{i315}	-0.588
W_{i411}	-0.423	W_{i412}	-0.121	W_{i413}	1.211	W_{i414}	1.983	W_{i415}	-1.067
W_{i511}	-1.442	W_{i512}	0.148	W_{i513}	-0.925	W_{i514}	-1.155	W_{i515}	-2.173
W_{i116}	1.720	W_{i117}	-0.178	W_{i118}	-1.573	W_{i119}	-1.325	W_{i120}	0.935
W_{i216}	0.911	W_{i217}	-1.138	W_{i218}	-1.760	W_{i219}	-1.059	W_{i220}	2.865
W_{i316}	1.142	W_{i317}	1.259	W_{i318}	1.884	W_{i319}	-0.347	W_{i320}	-0.874
W_{i416}	-1.826	W_{i417}	-1.712	W_{i418}	-0.962	W_{i419}	-1.092	W_{i420}	0.870
W_{i516}	0.333	W_{i517}	1.786	W_{i518}	0.939	W_{i519}	-2.050	W_{i520}	1.383
W_{i11}	-1.082	W_{i11}	-1.319	W_{i11}	0.130	W_{i11}	-1.080	W_{i11}	-0.889
W_{i11}	2.914	W_{i11}	-0.701	W_{i11}	2.717	W_{i11}	-0.947	W_{i11}	-2.063
W_{i11}	-0.918	W_{i11}	1.718	W_{i11}	-1.709	W_{i11}	-1.363	W_{i11}	1.840
W_{i11}	-2.016	W_{i11}	-0.436	W_{i11}	0.911	W_{i11}	-1.653	W_{i11}	-0.878
W_{i11}	-0.353	W_{i11}	-1.693	W_{i11}	-0.001	W_{i11}	-0.825	W_{i11}	-0.222
W_{i11}	-0.174	W_{i11}	-1.121	W_{i11}	-2.269	W_{i11}	0.444	W_{i11}	-2.878
W_{i11}	-0.493	W_{i11}	-0.078	W_{i11}	-0.301	W_{i11}	0.069	W_{i11}	-1.173
W_{i11}	1.970	W_{i11}	0.106	W_{i11}	2.412	W_{i11}	1.597	W_{i11}	0.829
W_{i11}	-1.014	W_{i11}	-1.746	W_{i11}	-0.887	W_{i11}	1.265	W_{i11}	-1.352
W_{i11}	1.816	W_{i11}	-1.842	W_{i11}	-0.272	W_{i11}	-1.847	W_{i11}	-0.577
W_{i11}	1.210	W_{i11}	-0.479	W_{i11}	-1.269	W_{i11}	1.599	W_{i11}	2.120
W_{i11}	-1.460	W_{i11}	-2.009	W_{i11}	-2.817	W_{i11}	1.288	W_{i11}	-0.223
W_{i11}	-0.861	W_{i11}	-0.080	W_{i11}	-0.070	W_{i11}	1.033	W_{i11}	-0.239
W_{i11}	1.450	W_{i11}	0.562	W_{i11}	0.402	W_{i11}	1.307	W_{i11}	2.140
W_{i11}	1.017	W_{i11}	-2.430	W_{i11}	1.065	W_{i11}	-1.142	W_{i11}	0.696
W_{i11}	-1.415	W_{i11}	-2.026	W_{i11}	-1.296	W_{i11}	0.613	W_{i11}	1.427
W_{i11}	-1.620	W_{i11}	1.004	W_{i11}	-1.228	W_{i11}	1.636	W_{i11}	-0.446
W_{i11}	2.329	W_{i11}	-0.821	W_{i11}	-1.208	W_{i11}	1.566	W_{i11}	0.165
W_{i11}	1.726	W_{i11}	-1.754	W_{i11}	1.162	W_{i11}	-1.399	W_{i11}	-2.359
W_{i11}	-1.547	W_{i11}	-0.374	W_{i11}	-1.920	W_{i11}	-1.182	W_{i11}	-0.929

Tabel 4. Bias dari *input layer* ke *output layer* [B_i]

bh ₁	-2.998	bh ₂	2.774	bh ₃	2.571	bh ₄	2.069	bh ₅	-1.908
bh ₆	2.204	bh ₇	-2.374	bh ₈	1.745	bh ₉	1.744	bh ₁₀	-1.525
bh ₁₁	-1.680	bh ₁₂	-1.324	bh ₁₃	0.633	bh ₁₄	0.686	bh ₁₅	-0.793
bh ₁₆	-0.689	bh ₁₇	0.025	bh ₁₈	0.700	bh ₁₉	0.658	bh ₂₀	0.007
bh ₂₁	-0.349	bh ₂₂	0.012	bh ₂₃	-0.445	bh ₂₄	-0.295	bh ₂₅	-0.483
bh ₂₆	-0.848	bh ₂₇	-1.402	bh ₂₈	-1.074	bh ₂₉	1.540	bh ₃₀	-1.015
bh ₃₁	2.063	bh ₃₂	-1.236	bh ₃₃	-1.749	bh ₃₄	1.965	bh ₃₅	1.955
bh ₃₆	-1.707	bh ₃₇	-2.384	bh ₃₈	-2.532	bh ₃₉	2.733	bh ₄₀	2.801

Tabel 5. Bobot dari *hidden layer* ke *output layer* [W_o]

W _{o1}	0.082	W _{o2}	-0.285	W _{o3}	-0.515	W _{o4}	0.734	W _{o5}	-0.752
W _{o6}	-0.341	W _{o7}	-0.363	W _{o8}	-0.122	W _{o9}	0.341	W _{o10}	0.061
W _{o11}	0.750	W _{o12}	-0.526	W _{o13}	-0.997	W _{o14}	0.365	W _{o15}	0.453
W _{o16}	0.108	W _{o17}	-0.281	W _{o18}	1.093	W _{o19}	0.173	W _{o20}	-0.849
W _{o21}	-0.998	W _{o22}	-0.508	W _{o23}	0.949	W _{o24}	-0.140	W _{o25}	0.395
W _{o26}	-0.123	W _{o27}	-0.767	W _{o28}	-0.764	W _{o29}	0.169	W _{o30}	-0.807
W _{o31}	0.666	W _{o32}	-1.115	W _{o33}	0.835	W _{o34}	0.318	W _{o35}	-0.752
W _{o36}	0.695	W _{o37}	0.397	W _{o38}	0.772	W _{o39}	0.402	W _{o40}	-0.406

Tabel 6. Bias dari *hidden layer* ke *output layer* [B₂] (Matriks 1x1)

b ₀	-0.081
----------------	--------

Tabel 7. Ukuran akurasi NN_Nspt (NC)

Tinjauan	Data Latih	Data Uji
RMSE	3,646	2,955
MAE	2,533	2,190

matriks bobot dan matriks bias dengan langkah-langkah berikut:

1. Normalisasi data masukan Xi sesuai dengan fungsi aktivasi yang digunakan. Dalam penelitian ini, dilakukan normalisasi data dengan menggunakan fungsi aktivasi *sigmoid bipolar*, data ditransformasikan menjadi rentang -1 hingga 1. Proses normalisasi menggunakan persamaan (1). Data masukan terdiri dari 5 neuron sehingga data masukan normalisasi ditampilkan dalam matriks X orde 1x5 {[X]_{1x5, (i)}} dimana i adalah jumlah data.

$$\text{Input Layer, } [X_i]_{1 \times 5, (i)} = \frac{1 - e^{-X_i}}{1 + e^{-X_i}} \quad (a)$$

2. Selanjutnya adalah menghitung operasi pada lapisan tersembunyi (*hidden layer*). Proses perhitungan dengan perkalian matriks. *Hidden layer* terdiri dari 40 neuron, oleh karena itu bobot dari *input layer* ke *hidden layer* ditampilkan dalam matriks W₁ orde 5x40 {[W]_{5x40, (i)}} dan bias dari *input layer* ke *hidden layer* ditampilkan dalam matriks b₁ orde 1x40 {[B]_{1x40, (i)}}. Selanjutnya

perkalian matriks dilakukan dengan menggunakan Persamaan (4) berikut:

Hidden Layer input,

$$Z_i]_{1 \times 40, (i)} = [X_i]_{1 \times 5, (i)} [W_i]_{5 \times 40, (i)} + [b_i]_{1 \times 40, (i)} \quad (b)$$

3. Aktifkan *hidden layer* sesuai dengan fungsi aktivasi yang digunakan. Rumus yang digunakan adalah rumus aktivasi *sigmoid bipolar*,

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$$

dengan menggunakan Persamaan berikut:

Hidden Layer output,

$$[Z_o]_{1 \times 40, (i)} = f([Z_i]_i) = \frac{1 - e^{-[Z_i]_i}}{1 + e^{-[Z_i]_i}} \quad (c)$$

4. Perhitungan di lapisan keluaran. Proses penghitungannya menggunakan perkalian matriks dimana layer keluaran ditampilkan dalam matriks 1x1. Nilai *hidden layer* ditampilkan dalam matriks 1x40, bobot dari *hidden layer* hingga *output layer* dalam matriks 1x40, dan nilai bias dalam matriks 1x1. Proses perhitungan dengan menggunakan perkalian matriks dengan menggunakan Persamaan berikut:

Output Layer,

$$Y_i = [Z_o]_{1 \times 40, (i)} [W_o]_{40 \times 1, (i)} + [b_o]_{1 \times 1, (i)} \quad (d)$$

5. Fungsi aktivasi yang digunakan pada lapisan keluaran adalah fungsi linier dengan Persamaan berikut:

Output,

$$Y = f(Y_i) \quad (e)$$

Langkah terakhir adalah de-normalisasi nilai keluaran yang diaktifkan dengan menggunakan **Persamaan (1)**.


3.4 Diskusi

Kehandalan Model JST terbaik dapat dilihat pada perbedaan antara nilai SPT prediksi dan nilai SPT hasil peyelidikan. Efektifitas model JST yang direkomendasikan (NN-Nspt (NC)) akan dibandingkan dengan penelitian sebelumnya untuk menentukan tingkat keefektifan. Sebagai pembanding, akan dilakukan prediksi nilai SPT dengan menggunakan


korelasi konvensional Gambar 5 oleh Akca (Akca, 2003), Gambar 6 oleh Mayne (P. Mayne, 2006) dan Gambar 7 oleh Ahmed dkk (Ahmed et al., 2014). Proses prediksi nilai SPT ini menggunakan nilai Kc seperti yang dijelaskan pada bagian pendahuluan. **Tabel 8** di bawah ini menampilkan nilai RMSE dan MAE.

3.5 Prediksi berdasarkan model terbaik


Model korelasi terbaik adalah apabila nilai prediksi sama atau mendekati nilai target (nilai asli). Kedekatan




Gambar 4. Prediksi N-SPT menggunakan JST model NN_Nspt (NN)



Gambar 5. Prediksi nilai SPT menggunakan korelasi Akca (2003)




Gambar 6. Prediksi nilai SPT menggunakan korelasi Mayne (2006)




Gambar 7. Korelasi penggunaan N-SPT Ahmed et al. (2014)

Tabel 8. Prediksi nilai SPT menggunakan korelasi konvensional

Penelitian	Data Latih		Data Uji	
	RMSE	MAE	RMSE	MAE
Akca (2003)	12.117	8.988	11.943	10.314
Mayne (2006)	9.070	6.609	5.896	5.010
Ahmed et al. (2014)	9.462	6.844	7.399	6.005
Nugroho et al. (2020)	3,664	2,533	2,955	2,190



Gambar 9. Design chart prediksi N-SPT VS N-SPT asli



Gambar 10. Bagan desain qc VS N-SPT

Tabel 9. Verifikasi prediksi N-SPT menggunakan NN_Nspt (NC) dengan korelasi konvensional oleh peneliti sebelumnya.

No	Variabel Bebas					Output				
	CPT		Properties Tanah			N-SPT (blows/ft)				
	Input					Output (Prediksi)				Asli
	q_c (kPa)	f_s (kPa)	$\sigma_{v,0}$ (kPa)	Sand (%)	Fines (%)	Akca (2003)	Mayne (2006)	Ahmed (2014)	Nugroho (2020)	ASTM
1	830.077	54.332	61.950	97.84	2.160	1.129	1.895	1.634	3.937	5
2	5787.900	84.517	42.005	56.38	43.62	7.875	13.214	11.394	9.689	10
3	6848.362	249.26	86.820	98.80	1.200	9.317	15.636	13.481	15.667	15
4	4640.885	215.82	180.12	99.40	0.600	6.314	10.596	9.136	20.482	20
5	7470.692	97.345	164.56	92.20	7.800	10.164	17.056	14.706	25.310	26
6	14262.23	49.050	110.40	98.12	1.890	19.404	32.562	28.075	29.493	30
7	7429.189	151.30	357.50	78.70	21.30	10.108	16.962	14.624	35.922	36
8	20110.50	155.33	163.78	68.38	31.62	27.361	45.914	39.588	41.797	42
9	11104.92	158.92	288.67	94.75	5.250	15.109	25.354	21.860	43.869	46
10	24525.00	98.10	361.67	81.44	18.56	33.367	55.993	48.278	51.810	50
11	24525.000	98.100	363.320	79.62	20.38	33.367	55.993	48.278	59.483	59

nilai prediksi dan nilai target bisa terlihat dari nilai R^2 . Jika nilai $R^2=1$, artinya nilai prediksi sama dengan nilai target

Gambar 8 (a) dan (b) adalah diagram desain antara nilai SPT yang diprediksi dan nilai SPT asli. Dalam design chart ini, ditampilkan garis regresi linier dari prediksi dengan JST dan prediksi dengan korelasi konvensional. Prediksi N-SPT menggunakan JST memberikan hasil yang lebih akurat dan efektif dibandingkan dengan korelasi konvensional, hal ini terlihat melalui nilai R^2 JST (warna merah) yang lebih besar atau mendekati 1 dibandingkan dengan perkiraan konvensional. Pada data latih $R^2 = 0,9103$ dan data uji $R^2 = 0,9311$.

Gambar 9 (a) dan (b) merupakan design chart antara nilai tahanan ujung (q_c) dan nilai SPT (N-SPT), pada grafik ini menunjukkan gabungan regresi linier dari data asli, prediksi menggunakan JST dan prediksi menggunakan 3 korelasi dengan peneliti sebelumnya. Pada grafik ini terlihat jelas bahwa regresi linier pada JST menunjukkan hasil yang sangat mendekati data asli, terlihat bahwa regresi linier pada JST (hitam) hampir bertepatan dengan regresi linier pada data asli (pada merah), dimana dapat diartikan bahwa prediksi dengan JST hampir mendekati nilai sebenarnya di lapangan.

Selanjutnya untuk mengetahui efektifitas prediksi nilai SPT menggunakan jaringan saraf tiruan dibandingkan dengan prediksi nilai SPT menggunakan korelasi konvensional. Pada **Tabel 9** di bawah ini, beberapa contoh perbandingan prediksi nilai SPT menggunakan jaringan saraf tiruan dan korelasi konvensional.

4. Kesimpulan

Berdasarkan penelitian yang telah dilakukan, didapatkan kesimpulan sebagai berikut:

1. Jaringan saraf tiruan dianggap mampu dan efisien dalam memprediksi nilai SPT pada penelitian ini. Pernyataan ini didukung dengan nilai error yang kecil dan tingkat akurasi yang tinggi dibandingkan dengan korelasi konvensional. Pada data latih didapatkan nilai RMSE 3.646, MAE 2.533 dan R^2 0.9103 sedangkan pada data uji didapatkan nilai RMSE 2.955, MAE 2.190, dan R^2 0.9311.
2. Arsitektur jaringan saraf tiruan dengan performa terbaik didapatkan yaitu model dengan 1 hidden layer dan 40 neuron pada hidden layer. Fungsi aktivasi yang digunakan adalah sigmoid bipolar/tansig, fungsi pelatihan traincgb dan menggunakan algoritma Backpropagation.
3. Design chart hubungan antara N-SPT Asli dan N-SPT prediksi seperti pada **Gambar 8**. dan design chart antara nilai q_c dan N-SPT seperti pada **Gambar 9**. menunjukkan bahwa prediksi nilai SPT menggunakan JST menunjukkan hasil yang hampir mendekati dengan nilai di lapangan, hal ini dapat dilihat dari garis regresi data asli hampir berhimpitan dengan garis regresi prediksi dengan JST.

Ucapan Terima Kasih

Terima kasih penulis ucapkan kepada Laboratorium Mekanika Tanah Fakultas Teknik Universitas Riau dan juga kepada CV. Geoteknik Multi Services yang telah menyediakan data hasil pengujian lapangan dan pengujian laboratorium. Data-data tersebut sangat berguna bagi penulis dalam proses penelitian hingga penelitian ini selesai.

Daftar Pustaka

- Ahmed, S. M., Agaiby, S. W., & Abdel-Rahman, A. H. (2014). A unified CPT-SPT correlation for non-crushable and crushable cohesionless soils. *Ain Shams Engineering Journal*, 5(1), 63–73

- Akca, N. (2003). Correlation of SPT-CPT data from the United Arab Emirates. *Engineering Geology*, 67 (3–4), 219–231
- Alam, M., Aaqib, M., Sadiq, S., Mandokhail, S. J., Adeel, M. B., Maqsood-Ur-Rehman, & Kakar, N. A. (2018). Empirical SPT-CPT correlation for soils from Lahore, Pakistan. *IOP Conference Series: Materials Science and Engineering*, 414 (1)
- Chen, Y.-L., Azzam, R., & Zhang, F.-B. (2006). The displacement computation and construction pre-control of a foundation pit in Shanghai utilizing FEM and intelligent methods. *Geotechnical & Geological Engineering*, 24(6), 1781–1801.
- dos Santos, M. D., & Bicalho, K. V. (2017). Proposals of SPT-CPT and DPL-CPT correlations for sandy soils in Brazil. *Journal of Rock Mechanics and Geotechnical Engineering*, 9(6), 1152–1158.
- Erzin, Y., & Tuskan, Y. (2017). Prediction of standard penetration test (SPT) value in Izmir, Turkey using radial basis neural network. *Celal Bayar Üniversitesi Fen Bilimleri Dergisi*, 37–41.
- Fernando, H., Nugroho, S. A., Suryanita, R., & Kikumoto, M. (2021). Prediction of SPT value based on CPT data and soil properties using ANN with and without normalization. *International Journal of Artificial Intelligence Research*, 5(2), 123–131.
- Ghaderi, A., Abbaszadeh Shahri, A., & Larsson, S. (2019). An artificial neural network based model to predict spatial soil type distribution using piezocone penetration test data (CPTu). *Bulletin of Engineering Geology and the Environment*, 78 (6), 4579–4588.
- Goh, A. T. C. (2002). Probabilistic neural network for evaluating seismic liquefaction potential. *Canadian Geotechnical Journal*, 39(1), 219–232.
- Jaksa, M. B. (1995). The influence of spatial variability on the geotechnical design properties of a stiff, overconsolidated clay. *Ph.D. Thesis, University of Adelaide, Australia., December.*
- Kuo, Y. L., Jaksa, M. B., Lyamin, A. V., & Kaggwa, W. S. (2009). ANN-based model for predicting the bearing capacity of strip footing on multi-layered cohesive soil. *Computers and Geotechnics*, 36(3), 503–516.
- Kurup, P. U., & Griffin, E. P. (2006). Prediction of soil composition from CPT data using general regression neural network. *Journal of Computing in Civil Engineering*, 20(4), 281–289.
- Lingwanda, M. I., Larsson, S., & Nyaoro, D. L. (2015). Correlations of SPT, CPT and DPL Data for Sandy Soil in Tanzania. *Geotechnical and Geological Engineering*, 33(5), 1221–1233.
- Mayne, P. (2006). In-situ test calibrations for evaluating soil parameters. In *Characterisation and Engineering Properties of Natural Soils*. Taylor & Francis.
- Nugroho, S. A., Fernando, H., & Suryanita, R. (2021). Prediction of SPT Value on Cohesive Soil Using Artificial Neural Networks. *Jurnal Informatika*, 15(2), 103–114.
- Nugroho, S. A., Fernando, H., & Suryanita, R. (2022). Estimation of Standard Penetration Test Value on Cohesive Soil Using Artificial Neural Network Without Data Normalization. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 11(1), 210–220.
- Padmini, D., Ilamparuthi, K., & Sudheer, K. P. (2008). Ultimate bearing capacity prediction of shallow foundations on cohesionless soils using neurofuzzy models. *Computers and Geotechnics*, 35(1), 33–46.
- Shahin, M. A., Jaksa, M. B., & Maier, H. R. (2005). Neural network based stochastic design charts for settlement prediction. *Canadian Geotechnical Journal*, 42(1), 110–120.
- Shahri, A., Juhlin, C., & Malemir, A. (2014). A reliable correlation of SPT-CPT data for southwest of Sweden. *Electronic Journal Of Geotechnical Engineering*.
- Tarawneh, B. (2017). Predicting standard penetration test N-value from cone penetration test data using artificial neural networks. *Geoscience Frontiers*.
- Zhao, H. (2008). Slope reliability analysis using a support vector machine. *Computers and Geotechnics*, 35(3), 459–467.

