

## Analisis Kestabilan Lereng Menggunakan Artificial Neural Network : Sebuah Tinjauan Pustaka

Risaldi Hidayat<sup>1</sup>, S. Koesnaryo<sup>2</sup>, Barlian Dwinagara<sup>2</sup>, Singgih Saptono<sup>2</sup>, Eddy Winarno<sup>2</sup>

<sup>1</sup> Mahasiswa Program Studi Magister Teknik Pertambangan, Universitas Pembangunan Nasional "Veteran" Yogyakarta

<sup>2</sup> Pengajar Program Studi Magister Teknik Pertambangan, Universitas Pembangunan Nasional "Veteran" Yogyakarta

Korespondensi: risaldi28@gmail.com

### ABSTRAK

Beberapa tahun terakhir, pendekatan jaringan syaraf tiruan atau *artificial neural network* (ANN) telah berhasil digunakan untuk pemodelan hampir semua aspek masalah rekayasa geoteknik terutama dalam kestabilan lereng. Berdasarkan komparasi yang dilakukan makalah ini menunjukkan bahwa ANN memiliki banyak keuntungan jika masalah tidak dapat diselesaikan secara matematis serta dapat menangani kumpulan data yang banyak. Ada berbagai algoritma cerdas tersedia, oleh karenanya ANN bukanlah konsep baru. Namun, kemampuan ANN dalam memecahkan masalah rekayasa geoteknik yang kompleks (seperti yang ditemukan dalam analisis kestabilan lereng) merupakan keunggulan utamanya. Sehingga dalam makalah ini bertujuan untuk memberikan gambaran mengenai pemodelan *artificial neural network* dalam analisis kestabilan lereng sebagai bagian dari permasalahan rekayasa geoteknik serta arah penelitian ANN yang perlu mendapat perhatian lebih lanjut di masa depan.

Kata kunci: kestabilan lereng, jaringan syaraf tiruan, kecerdasan buatan, rekayasa geoteknik.

### ABSTRACT

*Over the last few years, artificial neural network (ANN) have been used successfully for modeling almost all aspect of geotechnical engineering problems especially in slope stability. Based on the comparison in this paper, that ANN has many advantages if the problem cannot be solved by mathematically and handle large data set. There are various intelligent algorithms available, therefore ANN is not a new concept. However, ANN's ability to solve complex geotechnical engineering problems (such as, which is found within the slope stability analysis) is its main advantage. So, this paper to provide an overview of ANN modeling in slope stability analysis as part of geotechnical engineering problems and research direction of ANN that needs further attention in the future.*

*Keyword: slope stability, artificial neural network, artificial intelligence, geotechnical engineering.*

Keterangan

### 1. PENDAHULUAN

Stabilitas lereng merupakan faktor yang sangat penting dalam kegiatan penambangan karena menyangkut keselamatan dan kelancaran aktivitas penambangan. Permasalahan yang selalu dihadapi dalam menganalisis kestabilan lereng adalah adanya ketidakpastian dan kompleksitas. Akibatnya, solusi eksak pada rekayasa geoteknik bersifat indeterministik atau bersifat probabilitas. Hal tersebut disebabkan adanya banyak parameter yang tidak diketahui maupun tidak dapat dikendalikan, sehingga penggunaan model matematik konvensional pada masalah geoteknik menjadi sulit [1].

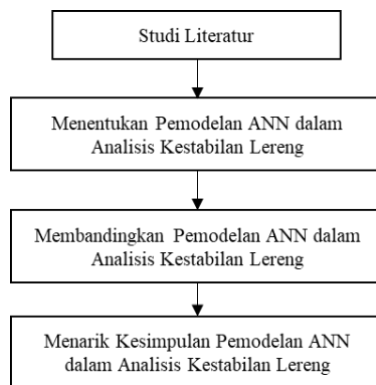
Semakin berkembangnya teknologi membuat kecerdasan buatan (*artificial intelligence* atau AI) banyak digunakan sebagai metode alternatif. Teknik AI mulai digunakan dalam klasifikasi stabilitas lereng untuk menggantikan cara scientific yang tidak mampu memecahkan masalah geologi kompleks yang sulit dipecahkan. Sementara *artificial neural networks* (ANN) adalah bagian dari AI yang merupakan sistem komputasi fleksibel yang memiliki kemampuan menangkap karakteristik dasar non-linier dan kompleks dari setiap proses yang karakteristik kinerjanya seperti jaringan syaraf biologis. ANN mewakili keseluruhan interkoneksi sistem bersama dengan bobot numerik yang dapat diatur berdasarkan proses pelatihan, sehingga model menjadi adaptif terhadap input dan output dalam mengatasi masalah variable yang terlalu banyak untuk disederhanakan. Selain itu, ANN cocok untuk *inverse modeling* ketika hubungan numerik antara variabel input dan output tidak diketahui dan tidak dapat ditentukan [2].

ANN dengan demikian sangat cocok untuk memodelkan perilaku kompleks sebagian besar permasalahan rekayasa geoteknik yang pada dasarnya menunjukkan variabilitas yang ekstrem seperti stabilitas lereng. Kemampuan pemodelan dalam proses pembelajar, telah memberikan keunggulan JST atas sebagian besar metode pemodelan tradisional karena tidak perlu membuat asumsi tentang aturan dasar yang mengatur

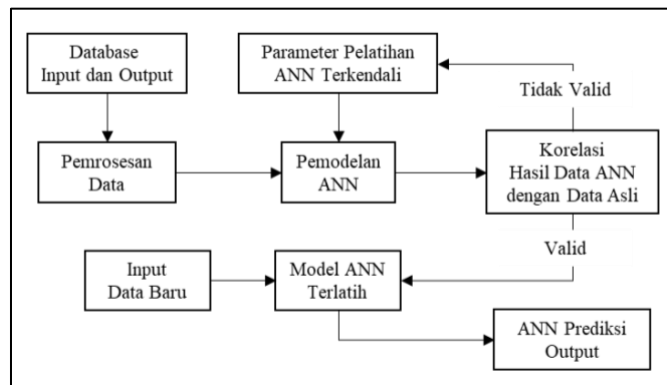
masalah yang dihadapi [3]. Oleh karena itu, makalah ini bertujuan untuk memberikan gambaran mengenai pendekatan ANN dalam analisis kestabilan lereng yang terkait dengan prediksi maupun klasifikasi serta arah penelitian ANN yang perlu mendapat perhatian lebih lanjut di masa depan.

## 2. METODE PENELITIAN

Tahapan penelitian dimulai dengan literature review yang merupakan proses kritis mendalam dan evaluasi terhadap penelitian serupa sebelumnya. Jurnal yang akan di review sejumlah 30 jurnal internasional untuk mengetahui kompetensi metode ANN dalam menganalisis nilai kestabilan suatu lereng. Metodologi yang digunakan pada penelitian ini yaitu metode kuantitatif. Rincian prosedur penelitian yang dilakukan penulis dirangkum pada bagan alir yang disajikan pada Gambar 1.



Gambar 1. Diagram Alir Penelitian



Gambar 2. Diagram Alir Metodologi Artificial Neural Network

## 3. HASIL DAN ANALISIS

### 3.1. Artificial Neural Network

Artificial Neural Network adalah bentuk kecerdasan buatan atau pendekatan pengolahan informasi yang memiliki karakteristik mirip seperti jaringan syaraf biologi, khususnya sel otak manusia dalam memproses informasi. Metode ini dapat menyelesaikan permasalahan yang kompleks serta mempunyai fitur *self-learning* yang membuat metode ini dapat menghasilkan hasil yang lebih baik seiring banyaknya data yang dimiliki.

Banyak penulis yang telah menjelaskan struktur dan operasi ANN (Fausett, 1994 dan Zurada, 1992). ANN terdiri dari sejumlah neuron buatan yang dikenal sebagai node. Untuk multilayer perceptron (MLP) merupakan ANN yang paling umum digunakan untuk dalam rekayasa geoteknik. MLP terdiri dari banyak lapisan yang jumlah node diatur dalam lapisan: input layer, output layer, dan satu atau lebih lapisan perantara yang disebut hidden layer. Setiap node dalam lapisan tertentu yang terhubung ke banyak node pada lapisan lainnya melalui koneksi berbobot. Dari banyak node lainnya, node individu menerima input berbobotnya, yang dijumlahkan dan unit bias atau ambang batas ditambahkan atau dikurangi. Unit bias digunakan untuk menskalakan input ke rentang yang berguna untuk meningkatkan sifat konvergen jaringan syaraf. Hasil proses tersebut diikuti dengan fungsi transfer (misal: sigmoid) untuk menghasilkan keluaran node.

ANN dapat dikategorikan berdasarkan 2 kriteria utama yaitu aturan pembelajaran yang digunakan dan hubungan antara node. Berdasarkan aturan pembelajaran, ANN dapat dibagi menjadi supervised dan unsupervised. Jaringan supervised disajikan dengan serangkaian input model histori dan output yang sesuai diinginkan. Output aktual dari jaringan dibandingkan dengan output yang diinginkan dan kesalahan dihitung. Kesalahan ini digunakan untuk menyesuaikan bobot koneksi antara input dan output model untuk mengurangi kesalahan antara output aktual dan yang diprediksi oleh ANN. Sedangkan jaringan unsupervised, jaringan hanya disajikan dengan input dan tidak ada output yang diinginkan. Jaringan itu sendiri menyesuaikan bobot koneksi sesuai dengan nilai input. Berdasarkan koneksi antara node, ANN dibagi menjadi feedforward dan feedback. Dalam jaringan feedforward, koneksi antara node hanya dalam arah maju. Sedangkan jaringan feedback, hubungan antara node arah proses pelatihan dalam arah maju dan mundur [4]. Dengan demikian tahapan proses pengembangan model ANN disajikan berupa diagram alir yang dapat dilihat pada Gambar 2.

#### 3.1.1. Masalah Pemodelan ANN

Dalam meningkatkan kinerja model ANN perlu dikembangkan secara sistematis yang bertujuan untuk mengatasi faktor-faktor utama seperti penentuan input yang memadai, pembagian data, pra-pemrosesan, pemilihan arsitektur jaringan yang sesuai, beberapa parameter internal yang mengontrol metode optimasi, kriteria penghentian dan validasi model yang disajikan sebagai berikut [5].

#### a. Penentuan Input Model

Penentuan variabel input model dalam mengembangkan model ANN secara substansial memiliki dampak paling signifikan terhadap kinerja model. Menyajikan sebanyak mungkin variabel input ke model ANN biasanya meningkatkan jaringan mengakibatkan penurunan kecepatan pemrosesan dan pengurangan efisiensi jaringan. Hal ini dapat menggunakan pendekatan model bebas, yang menggunakan ukuran ketergantungan linier, seperti korelasi maupun ukuran ketergantungan non-linier, seperti saling informasi yang bertujuan untuk mendapatkan input model yang signifikan sebelum mengembangkan model ANN.

#### b. Divisi Data

Pendivisian atau pembagian data dilakukan untuk meminimalkan kesalahan antara keluaran model dan nilai terukur pada model tertentu. Kinerja terbaik ANN ketika model tidak melakukan ekstrapolasi diluar jangkauan data yang digunakan untuk proses pembelajaran. Sehingga dalam pembagian data yang tersedia dibagi menjadi 3 bagian yaitu training, testing, dan validating set. Training set digunakan untuk menyesuaikan bobot dan konstruksi model, testing set digunakan untuk memeriksa kinerja model serta menentukan penghentian pelatihan, sedangkan validating set digunakan untuk memperkirakan kinerja jaringan terlatih pada lingkungan yang diterapkan. Pembagian data dalam pemodelan ANN memiliki dampak yang signifikan pada hasil yang diperoleh, karena ANN mengalami kesulitan untuk mengekstrapolasi di luar jangkauan data yang tersedia, semua pola yang terdapat dalam data perlu dimasukkan ke dalam set kalibrasi [6].

#### c. Pra-pemrosesan Data

Setelah data yang tersedia telah dibagi ke dalam himpunan bagiannya (pelatihan, pengujian dan validasi), penting untuk melakukan pra-pemrosesan data dalam bentuk yang sesuai sebelum diterapkan pada model ANN. Pra-pemrosesan data dilakukan berupa penskalaan data, normalisasi dan transformasi yang bertujuan untuk memastikan semua variabel mendapatkan perhatian yang sama selama proses pelatihan, mempercepat proses pembelajaran dan meningkatkan kinerja ANN.

#### d. Penentuan dan Optimasi Model

Menentukan arsitektur jaringan adalah salah satu tugas yang paling penting dan sulit dalam pengembangan model ANN, tidak ada pendekatan terpadu untuk penentuan model ANN yang optimal. Sehingga untuk mendapatkan hubungan antar input dan output yang optimal dan model yang baik, terdapat beberapa parameter terkendali model yang dapat diperhatikan sebagai berikut.

- **Number of Hidden Layer**, salah satu parameter umum yang digunakan untuk mencapai model ANN optimal dengan memperbaiki jumlah hidden layer. Untuk MLP, penggunaan satu hidden layer cukup untuk mendekati setiap fungsi kontinu asalakan diberikan nilai bobot koneksi yang cukup (Hornik, et al. 1989). Selain itu, beberapa peneliti (Flood, et al. 1994; Ripley, 1996; Sarle, 1994) menyatakan bahwa penggunaan lebih dari satu lapisan tersembunyi memberikan fleksibilitas yang diperlukan untuk memodelkan fungsi kompleks dalam banyak situasi, dimana hidden layer pertama digunakan untuk mengekstrak fitur lokal dari pola input dan hidden layer selanjutnya berguna untuk mengekstrak fitur global dari pola pelatihan. Namun, dapat dipertimbangkan bahwa penggunaan lebih dari satu hidden layer dapat memperlambat proses pelatihan secara signifikan dan meningkatkan kemungkinan terjebak dalam minimum lokal.
- **Number of Node**, dimana node pada input dan output layer dibatasi oleh jumlah variabel input dan output model masing-masing. Prosedur trial and error, umumnya digunakan dalam rekayasa geoteknik untuk menentukan jumlah dan konektivitas dari node hidden layer dapat digunakan. Sehingga menjaga jumlah node hidden layer seminimal mungkin, dengan syarat kinerja yang memuaskan tercapai dan selalu lebih baik, karena dapat mengurangi waktu komputasi yang dibutuhkan untuk pelatihan, membantu model mencapai kinerja generalisasi yang lebih baik, membantu menghindari masalah overfitting, dan memungkinkan model yang terlatih untuk dianalisis lebih mudah.
- **Training Function**, parameter ini bertujuan untuk mencapai intensitas proses pelatihan, efektivitas dan kecepatan mencapai konvergensi dari pelatihan. Secara umum training function yang sering digunakan diantaranya trainlm, traingd, traingdx, dan traingdm, yang dapat mempengaruhi parameter berikutnya dalam pelatihan pada optimasi model ANN.
- **Transfer function**, atau fungsi aktivasi disimulasikan pada hidden dan output layer bertujuan untuk mengontrol nilai bobot dan error dengan penentuan nilai batas ambang (threshold).
- **Learning rate**, merupakan laju pembelajaran untuk mempercepat laju iterasi pelatihan, dimana semakin besar learning rate maka semakin cepat pula proses pelatihan. Akan tetapi jika learning rate terlalu besar,

maka algoritma menjadi tidak stabil dan mencapai titik minimum lokal. Titik minimum lokal adalah suatu keadaan titik yang dihasilkan datanya sama dengan hasil pelatihan, jadi nilai kesalahan adalah nol dan semua data pelatihan sama dengan data prediksi model ANN.

- **Momentum coefficient**, sama halnya learning rate parameter ini bertujuan meningkatkan waktu pelatihan, sehingga pemberian momentum pada perubahan bobot menyebabkan perubahan yang cukup besar yaitu pada proses waktunya, semakin besar nilai momentum yang diberikan semakin cepat pula waktu pelatihan yang dibutuhkan. Namun jika nilai momentum yang diberikan mendekati nilai maksimal momentum yaitu mendekati nilai satu maka akan menyebabkan overshoot dan overfitting.

#### e. Kriteria Berhenti

Kriteria berhenti digunakan untuk memutuskan kapan harus menghentikan proses pelatihan. Banyak pendekatan yang dapat digunakan untuk kriteria berhenti diantaranya setelah menghasilkan sejumlah pelatihan yang benar, ketika kesalahan pelatihan mencapai nilai yang cukup kecil, atau ketika tidak ada atau sedikit perubahan dalam kesalahan pelatihan terjadi. Namun, contoh kriteria penghentian tersebut dapat menyebabkan model berhenti sebelum waktunya. Oleh karena itu, gagasan dasar dari kriteria penghentian ini adalah bahwa kinerja model harus menyeimbangkan kompleksitas model dengan jumlah data pelatihan dan kesalahan model.

#### f. Validasi Model

Setelah fase pelatihan model telah berhasil dicapai, kinerja model yang dilatih harus divalidasi. Tujuan dari fase validasi model adalah untuk memastikan bahwa model memiliki kemampuan untuk menggeneralisasi dalam batas-batas yang ditetapkan oleh data pelatihan dengan cara yang kuat. Pendekatan yang dilakukan adalah dengan menguji kinerja JST terlatih pada set validasi independen, yang belum digunakan sebagai bagian dari proses pembuatan model. Jika kinerja tersebut memadai, model dianggap dapat menggeneralisasi dan dianggap kuat.

### 3.2. Aplikasi ANN dalam Analisis Kestabilan Lereng

Stabilitas lereng tanah dan batuan merupakan masalah rekayasa geoteknik yang kompleks karena sifat dan batuan yang heterogen, banyak parameter yang terlibat dan sulitnya menentukan parameter geoteknik. Dalam prakteknya, hanya gambaran umum perkiraan karakteristik fisik dan geometri lereng biasanya dapat diperoleh. Sehingga sulit untuk menentukan nilai parameter input penting secara akurat. Metode konvensional yang paling umum digunakan dalam analisis stabilitas lereng diantaranya metode kesetimbangan batas dan metode elemen hingga, berdasarkan pada penyederhanaan asumsi dan biasanya memerlukan prosedur tertentu yang membutuhkan waktu.

Metode ANN menyediakan kemampuan deskriptif dan prediktif, sehingga ruang lingkup utama dari pekerjaan ini adalah untuk menerapkan metodologi di atas dalam masalah estimasi stabilitas lereng. Untuk meramalkan faktor keamanan (FoS) maupun status stabilitas (SS) pada kasus lereng batuan atau tanah, faktor-faktor yang mempengaruhi FoS dan SS harus ditentukan. Karena kualitas data dapat mempengaruhi kualitas model yang didasarkan pada penilaian teknik untuk menghindari pemilihan model yang mungkin tidak sesuai dengan permasalahan yang sedang dipelajari. Dan data pada wilayah satu dengan yang lainnya juga perlu dipertimbangkan saat mempertimbangkan penggunaan ANN yang disebabkan setiap wilayah memiliki karakteristik geologi yang unik dan berbeda.

Banyaknya pendekatan ANN dalam analisis kestabilan lereng yang telah dilakukan. Dimana model yang dikembangkan menyajikan representasi sistem yang terstruktur dan transparan, memungkinkan interpretasi hubungan antara faktor keamanan lereng, status stabilitas lereng, dan hubungan parameter yang berkontribusi dalam stabilitas lereng, serta kelebihan dan kekurangan dari metode ANN yang disajikan pada Tabel 1 dan Tabel 2.

Tabel 1. Komparasi Hasil Analisis Kestabilan Lereng menggunakan Metode ANN

Reff	Alg.	Model	FA	Data	Input	Output	Validasi
[7]	BP	6-6-1	Logsig	80	$\gamma, c, \phi, \beta, H, r$	FoS & SS	RMSE = 0.209
[8]	BP	6-6-1	Logsig	32	$\gamma, c, \phi, \beta, H, r$	FoS & SS	R2 = 0.998; R = 0.001
[9]	BP	5-8-1	Logsig	43	$\gamma, c, \phi, \beta, H, r$	FoS	MSE = 0.0025
[10]	BA	6-7-2-1	Purelin	41	$\gamma, c, \phi, \beta, H, r$	FoS	RMSE = 0.015
[11]	BP	6-6-6-1	Logsig	1000	$x, y, c, \phi, \beta, Sr, a_h, a_v$	FoS	R2 = 0.954
[12]	BP	6-6-1	Logsig	67	$\gamma, c, \phi, \beta, H, r$	FoS	COD = 0.999
[13]	BP	6-8-1	Purelin	18	$\gamma, c, \phi, \beta, H, r$	SS	MSE = 0.001
[14]	BP	6-10-10-1	Logsig	51	$\gamma, c, \phi, \beta, H, r$	FoS	R2 = 0.9789; R = 0.0534
[15]	BP	6-6-1	Logsig	46	$\gamma, c, \phi, \beta, H, r$	FoS & SS	R2 = 0.99; RMSE = 0.001
[16]	BP	7-5-1	Logsig	5184	$\gamma, c, \phi, \cot \beta, H, M, R$	FoS	R2 = 0.986; RMSE = 0.13
[17]	BP	6-6-7-1	Logsig	100	$\gamma, c, \phi, \beta, H, h$	FoS	R2 = 0.99; R = 0.001
[18]	BP	6-7-1	Logsig	520	$c, \phi, \beta, H, GRW, Bc$	FoS	%error = 0.00017
[19]	BP	5-7-1	Tansig	190	$\gamma, c, \phi, \beta, H$	FoS	R2 = 0.9966; MSE = 0.00073
[20]	BP	7-14-1	Logsig	57	$\gamma, c, \phi, \beta, H, r, d/H$	FoS	R2 = 0.95; MSE = 0.0035
[21]	BP	6-10-1	Logsig	200	$\gamma, c, \phi, \beta, H, r$	FoS	RMSE = 0.04; MAE = 0.031
[22]	BP	5-7-1	Logsig	110	$\gamma, c, \phi, \beta, H$	FoS	R2 = 0.98; MSE = 0.062
[23]	BA	4-6-1	Logsig	540	$\phi, \beta, n_d, \epsilon/\gamma H'$	FoS	R2 = 0.98; RMSE = 0.095
[24]	ELM	5-6-1	Logsig	5	$\beta, H, d/H, \text{ratio } c_u, \text{COV } c_u$	FoS	R = 0.0193; R2 = 0.998
[25]	BP	18-18-1-1	Logsig	141	$\beta, H, RT, CH_{avg}, \sigma_c, RQD, WEATH, M, GRW, DC, INST, BL$	FoS	R2 = 0.880
[26]	BP	4-5-1	Logsig	800	$\beta, \text{ratio } c_u, \rho, d/H$	FoS	R2 = 0.9875
[27]	BP	4-4-1	Logsig	630	$\beta, d/H, \text{ratio } c_u, Su$	FoS	R2 = 0.9939; RMSE=0.7039
[28]	BP	5-1-1	Logsig	243	$\gamma, c, \phi, \beta, H, r$	FoS	R2 = 0.901
[29]	BP	6-8-1	Logsig	153	$\gamma, c, \phi, \beta, H, r$	FoS	R2 = 0.8931
[30]	BP	8-10-10-1	Logsig	400	$c, \phi, \beta, H, E, D$	FoS	R2 = 0.959; RMSE = 0.0462
[31]	BP	5-10-1	Logsig	233	$\gamma, c, \phi, \beta, H$	FoS	R2 = 0.993; RMSE = 0.0037
[32]	BP	6-6-1	Logsig	28	$\gamma, c, \phi, \beta, H, r$	FoS	R2 = 0.999; RMSE = 0.032
[33]	BP	3-3-1	Tansig	64	$\beta, d/H, \text{ratio } c_u$	FoS	R2 = 0.999; RMSE = 0.0059
[34]	BP	3-10-1	Logsig	216	$\beta, H, Crh$	FoS	R2 = 0.999; RMSE = 0.0038
[35]	ASC	6-11-1	Logsig	189	$\gamma, c, \phi, \beta, H, Kb$	FoS	R2 = 0.984; RMSE = 0.023
[36]	GA	3-4-5-1	Logsig	100	$\gamma, \beta, H$	FoS	R2 = 0.979

Keterangan: Cetak tebal dan biru adalah parameter berpengaruh pada stabilitas lereng berdasarkan hasil analisis sensitivitas.

Tabel 2. Komparasi Kelebihan dan Kekurangan dari Metode ANN

Kelebihan	Kekurangan
<ul style="list-style-type: none"> <li>Metode ANN berbasis data dimana model dapat dilatih pada pasangan data input dan output untuk menentukan struktur dan parameter model [3].</li> <li>Metode ANN tidak perlu menyederhanakan masalah atau memasukkan asumsi apapun pada parameter input dalam proses pelatihan data. [10].</li> <li>Model ANN selalu dapat diperbarui untuk mendapatkan hasil yang lebih baik dengan menyajikan data pelatihan baru saat data baru tersedia yang menjadikan ANN sebagai pemodelan yang kuat dalam rekayasa geoteknik [10].</li> </ul>	<ul style="list-style-type: none"> <li>Metode ANN adalah tidak dapat menghasilkan persamaan matematis seperti model empiris [4].</li> <li>Struktur optimal dari JST yaitu parameter terkenal harus diidentifikasi secara apriori. Hal ini biasanya dilakukan melalui prosedur trial and error [8]</li> <li>Hubungan antara parameter input dan output sistem dijelaskan dalam matriks bobot dan bias yang saat ini tidak dapat diakses oleh pemahaman pengguna [34].</li> </ul>

#### 4. KESIMPULAN

Beberapa pendekatan ANN dalam analisis kestabilan lereng yang disajikan dalam makalah ini, memberikan hasil yang mendekati hasil analisis metode empiris berdasarkan evaluasi performa model, sehingga pada makalah ini dapat ditarik kesimpulan sebagai berikut.

- Pemodelan ANN dengan penggunaan 1 hidden layer memiliki performa yang lebih baik
- Algoritma pembelajaran ANN dengan *Backpropagation* (BP) pilihan paling baik dan sering digunakan dalam menyelesaikan berbagai masalah prediksi dan klasifikasi dalam kasus ini yaitu kestabilan lereng.
- Parameter yang berpengaruh dalam kestabilan lereng diantaranya kohesi, sudut geser dalam ( $\phi$ ), tinggi lereng ( $H$ ), sudut kemiringan lereng ( $\beta$ ), faktor kedalaman ( $d/H$ ), kuat geser undrained ( $c_u$ ), kondisi air tanah (GRW) dan kondisi pelapukan (WEATH).

Terlepas dari keberhasilan ANN dalam rekayasa geoteknik dan disiplin ilmu lainnya, metode ANN mengalami kekurangan yang memerlukan perhatian lebih lanjut di masa mendatang berupa transparansi model, ekstrapolasi, dan ketidakpastian model, sehingga metode ANN untuk saat ini dapat diperlakukan sebagai pelengkap teknik komputasi konvensional daripada sebagai alternatif, atau sebagai solusi dalam pemeriksaan secara cepat dalam mendapatkan solusi (Flood & Kartam, 1994). Oleh karena itu, perbaikan dalam masalah tersebut sangat meningkatkan kegunaan model ANN dalam aplikasi rekayasa geoteknik.

#### UCAPAN TERIMA KASIH

Dalam penyusunan paper ini tidak terlepas dukungan dari berbagai pihak khususnya Kepada Prodi Magister Teknik Pertambangan UPN “Veteran” Yogyakarta.

#### DAFTAR PUSTAKA

- [1] Surjandari, N. S., Djajaputra, A. A., & RW, S. P. (2010). Artificial Neural Network Model for Analysis Ultimate Bearing Capacity of Single Pile.
- [2] Weiya XU and J.-F. SHAO. (1997). Application of ANNs in the rock slope engineering. Journal of University of Hydraulic and Electric Engineering. Vol 20: 9-20.
- [3] Sulewska, M. J. (2017). Applying artificial neural networks for analysis of geotechnical problems. Computer Assisted Methods in Engineering and Science. 18(4): 231-241.
- [4] Haykin, S., Vanneschi, L., and Castelli, M. (2018). Neural Networks and Learning Machines Third Edition. In Encyclopedia of Bioinformatics and Computational Biology: ABC of Bioinformatics: Vols. 1 – 3.
- [5] Shahin, M. A., Jaksa, M. B., and Maier, H. R. (2001). Artificial neural network applications in geotechnical engineering. Australian Geomechanics. 36(1): 49-62.
- [6] Tokar, S. A., and Johnson, P. A. (1999). Rainfall-runoff modeling using artificial neural networks. Journal of Hydrologic Engineering. 4(3): 232-239.
- [7] Xu, W., & Shao, J. F. (1998). Artificial neural network analysis for the evaluation of slope stability. In Application of Numerical Methods to Geotechnical Problems. Springer. 665-672.
- [8] Lu, P., & Rosenbaum, M. S. (2003). Artificial neural networks and grey systems for the prediction of slope stability. Natural Hazards. 30(3): 383-398.
- [9] Sakellariou, M. G., & Ferentinou, M. D. (2005). A study of slope stability prediction using neural networks. Geotechnical & Geological Engineering. 23(4): 419-445.
- [10] Shangguan, Z., Li, S., & Luan, M. (2009). Intelligent forecasting method for slope stability estimation by using probabilistic neural networks. Electron J Geotech Eng Bundle. Vol 13.
- [11] Choobasthi, A. J., Farrokhzad, F., & Barari, A. (2009). Prediction of slope stability using artificial neural network (case study: Noabad, Mazandaran, Iran). Arabian journal of geosciences. 2(4): 311-319.
- [12] Ahangar-Asr, A., Faramarzi, A., & Javadi, A. A. (2010). A new approach for prediction of the stability of soil and rock slopes. Engineering Computations.
- [13] Liang, H., & Zhang, H. (2010). Identification of slope stability based on the contrast of BP neural network and SVM. In 2010 3rd International Conference on Computer Science and Information Technology. Vol. 9: 347-350.
- [14] Jianping, J. (2011, August). BP neural networks for prediction of the factor of safety of slope stability. In 2nd International Conference on Computing, Control and Industrial Engineering. Vol. 2: 337-340.
- [15] Das, S. K., Biswal, R. K., Sivakugan, N., & Das, B. (2011). Classification of slopes and prediction of factor of safety using differential evolution neural networks. Environmental Earth Sciences. 64(1): 201-210.
- [16] Cetina, T. (2014). The prediction of the critical factor of safety of homogeneous finite slopes subjected to earthquake forces using neural networks and multiple regressions. Geomech Eng. 6(1): 1-15.
- [17] Gelisli, K., Kaya, T., & Babacan, A. E. (2015). Assessing the factor of safety using an artificial neural network: case studies on landslides in Giresun, Turkey. Environmental Earth Sciences. 73(12): 8639-8646.
- [18] Khandelwal, M., Rai, R., & Shrivastva, B. K. (2015). Evaluation of dump slope stability of a coal mine using artificial neural network. Geomechanics and Geophysics for Geo-energy and Geo-resources. 1(3): 69-77.
- [19] Abdalla, J. A., Attom, M. F., & Hawileh, R. (2015). Prediction of minimum factor of safety against slope failure in clayey soils using artificial neural network. Environmental Earth Sciences. 73(9): 5463-5477.

- [20] Kostić, S., Vasović, N., Todorović, K., & Samčović, A. (2016). Application of artificial neural networks for slope stability analysis in geotechnical practice. In 13th Symposium on Neural Networks and Applications. pp. 1-6.
- [21] Chakraborty, A., & Goswami, D. (2017). Prediction of slope stability using multiple linear regression (MLR) and artificial neural network (ANN). *Arabian Journal of Geosciences*. 10(17): 1-11.
- [22] Chakraborty, A., & Goswami, D. (2017). Slope stability prediction using artificial neural network (ANN). *International Journal of Engineering and Computer Science*. 6(6): 21845-21848.
- [23] Kumar, S., & Basudhar, P. K. (2018). A neural network model for slope stability computations. *Géotechnique Letters*. 8(2): 149-154.
- [24] Li, A. J., Lim, K., Chiu, C. K., & Hsiung, B. (2018). Application of artificial neural network in assessing fill slope stability. *International Journal of Geotechnical and Geological Engineering*. 12(2): 73-77.
- [25] Ferentinou, M., & Fakir, M. (2018). Integrating rock engineering systems device and artificial neural networks to predict stability conditions in an open pit. *Engineering Geology*. 246: 293-309.
- [26] Qian, Z. G., Li, et.al. (2019). An artificial neural network approach to inhomogeneous soil slope stability predictions based on limit analysis methods. *Soils and foundations*. 59(2): 556-569.
- [27] Tien Bui, D., Moayedi, H., Gör, M., Jaafari, A., & Foong, L. K. (2019). Predicting slope stability failure through machine learning paradigms. *ISPRS International Journal of Geo-Information*. 8(9): 395.
- [28] Majeed, M. Q., Hussein, M. K., & Mohammed, M. (2019). Slope Stability Prediction of Homogenous Earth Dam Caused by Fluid Particles Seeps by Using Artificial Neural Networks. *Journal of Advanced Research in Fluid Mechanics and Thermal Sciences*. 63(2): 295-301.
- [29] Liao, Z., & Liao, Z. (2020). Slope stability evaluation using backpropagation neural networks and multivariate adaptive regression splines. *Open Geosciences*. 12(1): 1263-1273.
- [30] Ray, A., Kumar, V., Kumar, A., Rai, R., Khandelwal, M., & Singh, T. N. (2020). Stability prediction of Himalayan residual soil slope using artificial neural network. *Natural Hazards*. 103(3): 3523-3540.
- [31] Omar, M., Che Mamat, R., Abdul Rasam, A. R., Ramli, A., & Samad, A. (2021). Artificial intelligence application for predicting slope stability on soft ground: A comparative study. *Int. J. Adv. Technol. Eng. Explor*. 8: 362-370.
- [32] Marrapu, B. M., Kukunuri, A., & Jakka, R. S. (2021). Improvement in Prediction of Slope Stability & Relative Importance Factors Using ANN. *Geotechnical and Geological Engineering*. 39(8): 5879-5894.
- [33] Moayedi, H. (2021). Two novel predictive networks for slope stability analysis using a combination of genetic programming and artificial neural network techniques. In *Proceedings of the International Conference on Innovations for Sustainable and Responsible Mining*. Springer. pp. 91-108.
- [34] Bharati, A. K., Ray, A., Khandelwal, M., Rai, R., & Jaiswal, A. (2022). Stability evaluation of dump slope using artificial neural network and multiple regression. *Engineering with Computers*. 38(3): 1835-1843.
- [35] Khajehzadeh, M., Taha, M. R., Keawsawasvong, S., Mirzaei, H., & Jebeli, M. (2022). An effective artificial intelligence approach for slope stability evaluation. 10: 5660-5671.
- [36] Mamata, R. C., et.al. (2022). Slope Stability Prediction of Road Embankment using Artificial Neural Network Combined with Genetic Algorithm. *Jurnal Kejuruteraan*. 34(1): 165-173.

## DAFTAR NOTASI

$\gamma$	Berat Jenis	RT	Rock Type
$c$	Kohesi	$CH_{avg}$	Curah Hujan Rata-Rata
$\phi$	Sudut Geser Dalam	$\sigma_c$	Kuat Tekan Uniaksial
$\beta$	Sudut Kemiringan Lereng	RQD	Rock Quality Designation
$H$	Tinggi Lereng	WEATH	Kondisi Pelapukan
$r$	Ratio Tekanan Pori	DC	Kondisi Bidang Diskontinu
$x$	Koordinat X	INST	Ketidakstabilan Sebelumnya
$y$	Koordinat Y	BL	Metode Peledakan
$Sr$	Derajat Kejenuhan	$\rho$	Laju Kenaikan Linier pada $c_u$ terhadap H
$a_h$	Koef. Horizontal Kegempaan	$S_u$	Surcharge on Slope
$a_v$	Koef. Vertikal Kegempaan	E	Modulus Young
M	Besaran Gempa	D	Kedalaman Material Redisual
R	Jarak dari Pusat Gempa	Crh	Ketebalan Material
h	Tinggi Muka Air Tanah	BP	Backpropagation Algorithm
GRW	Kondisi Air Tanah	BA	Bayesia Algorithm
Bc	Jumlah Jenjang Lereng	GA	Genetic Algorithm
$d/H$	Kedalaman Bedrock	ELM	Extreme Learning Machine Algorithm
$\hat{c}/\gamma H$	Koef. Non-Dimensional	ASC	Adaptive Sine Consine Algorithm
$n_d$	Faktor Kedalaman	FoS	Factor of Safety
$c_u$	Kuat Geser Undrained	SS	Stability Status