TUGAS AKHIR

OPTIMALISASI NILAI KEAMANAN LERENG PADA PERTAMBANGAN DI DUSUN TANJUNG BELIT, PROVINSI JAMBI MENGGUNAKAN ARTIFICIAL NEURAL NETWORK

(*OPTIMIZATION OF SLOPE STABILITY VALUE IN MINING AT TANJUNG BELIT VILLAGE, JAMBI PROVINCE USING ARTIFICIAL NEURAL NETWORK*)

Diajukan Kepada Universitas Islam Indonesia Yogyakarta Untuk Memenuhi Persyaratan Memperoleh Derajat Sarjana Teknik Sipil

Bagus Sadewa
21511192

PROGRAM STUDI TEKNIK SIPIL
FAKULTAS TEKNIK SIPIL DAN PERENCANAAN
UNIVERSITAS ISLAM INDONESIA

2025

TUGAS AKHIR

OPTIMALISASI NILAI KEAMANAN LERENG PADA PERTAMBANGAN DI DUSUN TANJUNG BELIT, PROVINSI JAMBI MENGGUNAKAN ARTIFICIAL NEURAL NETWORK
(*OPTIMIZATION OF SLOPE STABILITY VALUE IN MINING AT TANJUNG BELIT VILLAGE, JAMBI PROVINCE USING ARTIFICIAL NEURAL NETWORK*)

Disusun oleh

Bagus Sadewa
21511192

Telah diterima sebagai salah satu persyaratan
untuk memperoleh derajat Sarjana Teknik Sipil

Diuji pada tanggal 20 Agustus 2025

Oleh Dewan Penguji:

Pembimbing I	Penguji I	Penguji II
Anisa Nur A., S.T., M.Eng.	**Dr. Hanindya Kusuma A., S.T., M.T.**	**Astriana H., S.T., M.Eng.**
NIK: 215111305	**NIK: 045110407**	**NIK: 165111301**

26.08.25

Mengesahkan,
Ketua Program Studi Teknik Sipil

Ir. Yunalia Muntafi, S.T., M.T., Ph.D. (Eng)., IPM.
NIK: 095110101

PERNYATAAN BEBAS PLAGIASI

Dengan ini saya menyatakan bahwa Tugas Akhir yang telah saya kerjakan sebagai syarat untuk penyelesaian Program Sarjana di Program Studi Teknik Sipil, Fakultas Teknik Sipil dan Perencanaan, Universitas Islam Indonesia merupakan hasil karya saya sendiri. Saya menyadari pentingnya integritas akademik dan menghormati hak cipta serta kontribusi karya ilmiah dari pihak lain. Saya menyatakan bahwa dalam menyusun Tugas Akhir ini, saya telah secara tepat mencantumkan sumber informasi, data, referensi, kutipan, atau pendapat dari karya orang lain dengan mengikuti aturan penulisan sesuai dengan kaidah dan etika penulisan karya ilmiah. Apabila di kemudian hari dalam Tugas Akhir ini ditemukan seluruh atau sebagian adanya kesamaan atau plagiasi dengan karya orang lain, saya bersedia menerima konsekuensi dan sanksi sesuai dengan peraturan yang berlaku.

Demikian pernyataan bebas plagiasi ini saya buat dengan sebenarnya. Atas pernyataan ini, saya siap bertanggung jawab sepenuhnya.

Yogyakarta, 20 Agustus 2025

Yang membuat pernyataan,



Bagus Sadewa

(21511192)

HALAMAN DEDIKASI

Tugas Akhir ini Penulis persembahkan dengan penuh rasa cinta dan kerinduan kepada:

Ayah Penulis tercinta, Almarhum Drs. H. Saefudin Zuhri, M.M. bin H. Muhammad Kusnan Rifa'i yang telah tiada sebelum sempat melihat putra bungsumu ini menyelesaikan perjuangan yang pernah dijanjikannya untuk cepat diselesaikan ini. Inilah hari di mana Penulis akhirnya dapat menepati hutang janji yang Penulis buat kepada Almarhum.

Untukmu, Ayah. Di setiap sujud dan doaku, aku akan terus mengenangmu. Di setiap langkah perjalanan dan perjuangan hidupku, akan terus kuingat didikan dan nasihatmu. Doakan aku dari Surgamu yang indah itu, semoga aku tetap menjadi anak yang berbakti dan kelak menjadi sosok Ayah yang hebat seperti dirimu.
Al-Fatihah.

Penulis ingin berterima kasih banyak kepada Ibu Penulis, Hj. Yunelti, S.E., M.Pd. dan kakak-kakak Penulis: Agung Riadi, S.T., Angga Permana, M.Pd., Gr., Aditya Nugraha, S.T., dan Andi Jaya Putra, yang senantiasa memberikan doa dan semangat yang tiada henti, serta berkorban begitu banyak material agar Penulis bisa mendapatkan gelar Sarjana ini.

Terkhusus juga untuk dosen pembimbing Tugas Akhir Penulis, ibu Anisa Nur Amalina, S.T., M.Eng. yang seringkali Penulis repotkan dalam meminta bimbingan dan beliau selalu bersedia untuk membimbing dan juga memberikan banyak waktunya untuk membantu Penulis dalam segala kondisi dan banyak hal. Rasanya memiliki dosen pembimbing yang sudah seperti sahabat dekat.

Selain itu, Penulis juga berterima kasih kepada sahabat Penulis yaitu Rico yang juga berkontribusi terhadap penelitian ini karena telah memberikan bantuan ilmunya dan saran-saran kepada Penulis dalam pembuatan penelitian ini.

Terakhir, Penulis ingin mengucapkan terima kasih kepada Adhwa Haura Ulfah yang selalu membersamai Penulis dalam proses suka dan duka. Bersama dengannya, membuat perjalanan Penulis menjadi lebih berarti.

KATA PENGANTAR

Alhamdulillah puji dan rasa syukur yang senantiasa tercurahkan kehadirat Tuhan Yang Maha Esa, sehingga Penulis dapat menyelesaikan Tugas Akhir yang berjudul *Optimalisasi Nilai Keamanan Lereng pada Pertambangan di Dusun Tanjung Belit, Provinsi Jambi Menggunakan Artificial Neural Network*. Tugas Akhir ini merupakan salah satu syarat akademik dalam menyelesaikan studi tingkat sarjana di Program Studi Teknik Sipil, Fakultas Teknik Sipil dan Perencanaan, Universitas Islam Indonesia, Yogyakarta.

Dalam penyusunan Tugas Akhir ini, Penulis menghadapi banyak hambatan, namun berkat saran, kritik, bimbingan, dukungan semangat, serta bantuan dari berbagai pihak, Alhamdulillah Tugas Akhir ini dapat diselesaikan. Untuk itu, Penulis ingin mengucapkan terima kasih yang sedalam-dalamnya kepada:

1. Ibu Anisa Nur Amalina, S.T., M.Eng. selaku Dosen Pembimbing Tugas Akhir,
2. Ibu Dr. Hanindya Kusuma Artati, S.T., M.T. selaku Dosen Penguji I,
3. Ibu Astriana Hardawati, S.T., M.Eng. selaku Dosen Penguji II,
4. Bapak Ektorik Dimas, S.T. selaku Pembimbing Magang Penelitian di PT Cipta Kridatama, *site* Jambi, dan
5. Keluarga tercinta, terutama kedua orang tua, yang telah berkorban begitu banyak baik material maupun spiritual hingga selesainya Tugas Akhir ini.

Akhirnya Penulis berharap agar Tugas Akhir ini dapat memberikan banyak manfaat bagi berbagai pihak yang membacanya.

Yogyakarta, 20 Agustus 2025

Penulis,



Bagus Sadewa

(21511192)

DAFTAR ISI

HALAMAN JUDUL i
HALAMAN PENGESAHAN ii
PERNYATAAN BEBAS PLAGIASI iii
HALAMAN DEDIKASI iv
KATA PENGANTAR v
DAFTAR ISI vi
DAFTAR GAMBAR ix
DAFTAR TABEL xi
DAFTAR NOTASI DAN SINGKATAN xii
ABSTRAK xiv
ABSTRACT xv
BAB I PENDAHULUAN 1
1.1 Latar Belakang 1
1.2 Rumusan Masalah 4
1.3 Tujuan Penelitian 4
1.4 Manfaat Penelitian 4
1.5 Batasan Penelitian 5
BAB II TINJAUAN PUSTAKA 6
2.1 Tinjauan Umum 6
2.2 Penelitian Terdahulu 7
2.2.1 Analisis Stabilitas Lereng 7
2.2.2 Prediksi Stabilitas Lereng dengan *Machine Learning* (ML) 9
2.2.3 Optimalisasi Nilai Keamanan Lereng (SF) dengan Pemodelan *Artificial Neural Network* (ANN) 11
2.2.4 Penerapan Pemodelan *Artificial Neural Network* (ANN) dengan Bahasa Pemrograman Python 13
2.3 Perbandingan Penelitian Dahulu dan Penelitian Saat Ini 16
BAB III LANDASAN TEORI 22

3.1 Metode *Fellenius* (*Ordinary Method of Slice*) 22
3.2 *Slope/W* 24
3.3 *Artificial Neural Network* (ANN) 25
3.3.1 *Artificial Neuron* 26
3.3.2 Artisektur Jaringan *Artificial Neural Network* 29
3.3.3 *Hyperparameter Neural Network* 31
3.3.4 Pelatihan *Artificial Neural Network* 34
3.3.5 *Algoritma Backpropogation* 35
3.3.6 Pemodelan *Artificial Neural Network* 36
3.3.7 *Loss Function* 38
BAB IV METODE PENELITIAN 42
4.1 Tinjauan Umum 42
4.2 Subjek dan Objek Penelitian 42
4.3 Peraturan dan Standar yang Digunakan 45
4.4 Data Penelitian dan Metode Pengumpulan Data 46
4.5 Alat 47
4.6 Pelaksanaan Penelitian 48
4.6.1 Studi Literatur 48
4.6.2 Pengumpulan Data 49
4.6.3 *Explotatory Data Analysis* (EDA) 49
4.6.4 *Data Preprocessing* 50
4.6.5 Proses *Input* Data Geoteknik pada ANN 51
4.6.6 Pembuatan Arsitektur dan Pemodelan ANN 51
4.6.7 Pembahasan dan Kesimpulan 52
4.7 Analisis Data 52
4.8 Bagan Alir Penelitian dan *Data Preprocessing* 54
BAB V ANALISIS DAN PEMBAHASAN 57
5.1 Pemodelan Lereng 57
5.1.1 Kontur 57
5.1.2 *Inter-Ramp* 58
5.1.3 Variasi Model 59

5.1.4 Parameter Tanah dan Lereng 61
5.2 Analisis Lereng 64
5.3 Pengembangan Model *Artificial Neural Network* (ANN) 67
5.4 Pelatihan dan Pengujian Model *Artificial Neural Network* (ANN) 69
5.5 Hasil dan Evaluasi Model *Artificial Neural Network* (ANN) 72
BAB VI KESIMPULAN DAN SARAN 79
6.1 Kesimpulan 79
6.2 Saran 80
DAFTAR PUSTAKA 83

DAFTAR GAMBAR

Gambar 3.1 Lereng Dengan Busur Lingkaran Bidang Longsor 22
Gambar 3.2 Contoh Pemodelan Lereng dengan *Slope/W* 24
Gambar 3.3 Model *Artificial Neuron* 26
Gambar 3.4 Arsitektur Jaringan Saraf Lapis Tunggal 29
Gambar 3.5 Arsitektur Jaringan Saraf Lapis Jamak 30
Gambar 3.6 Arsitektur Jaringan Saraf Lapis Jamak 35
Gambar 4.1 Peta Lokasi Penelitian 43
Gambar 4.2 Potongan Penampang Lereng yang Ditinjau (Bagian Utara, *Central* PIT) 43
Gambar 4.3 Peta Area Kritis Lokasi Penelitian 44
Gambar 4.4 Ilustrasi Lereng 47
Gambar 4.5 Bagan Alir Penelitian 55
Gambar 4.6 Bagan Alir *Data Preprocessing* 56
Gambar 5.1 Lokasi Tinjauan Penelitian Lereng Asli dari Kontur 57
Gambar 5.2 Model Lereng Asli Berdasarkan *Inter-Ramp* (Batas Jenjang) 59
Gambar 5.3 Contoh Model dengan Variasi Sudut Kemiringan (α) 50 derajat 60
Gambar 5.4 Contoh Model dengan Variasi Sudut Kemiringan (α) 45 derajat 60
Gambar 5.5 Contoh Model dengan Variasi Sudut Kemiringan (α) 35 derajat 60
Gambar 5.6 Contoh Model dengan Variasi Sudut Kemiringan (α) 20 derajat 61
Gambar 5.7 Contoh Model dengan Variasi Sudut Kemiringan (α) 50 derajat yang Telah Dimasukkan Parameter Tanah dan Lereng 62
Gambar 5.8 Contoh Model dengan Variasi Sudut Kemiringan (α) 45 derajat yang Telah Dimasukkan Parameter Tanah dan Lereng 62
Gambar 5.9 Contoh Model dengan Variasi Sudut Kemiringan (α) 35 derajat yang Telah Dimasukkan Parameter Tanah dan Lereng 63
Gambar 5.10 Contoh Model dengan Variasi Sudut Kemiringan (α) 20 derajat yang Telah Dimasukkan Parameter Tanah dan Lereng 63

Gambar 5.11 Contoh Hasil Analisis Nilai Keamanan Lereng (SF) Model dengan Variasi Sudut Kemiringan (α) 45 derajat *Inter-Ramp* Atas 64
Gambar 5.12 Contoh Hasil Analisis Nilai Keamanan Lereng (SF) Model dengan Variasi Sudut Kemiringan (α) 45 derajat *Inter-Ramp* Tengah 65
Gambar 5.13 Contoh Hasil Analisis Nilai Keamanan Lereng (SF) Model dengan Variasi Sudut Kemiringan (α) 45 derajat *Inter-Ramp* Bawah 65
Gambar 5.14 Arsitektur ANN yang Digunakan 71
Gambar 5.15 Hasil Prediksi ANN Terhadap Optimalisasi Nilai Keamanan Lereng (SF) pada *Inter-Ramp* Atas 73
Gambar 5.16 Akurasi Hasil Model ANN pada *Inter-Ramp* Atas 73
Gambar 5.17 Hasil Prediksi ANN Terhadap Optimalisasi Nilai Keamanan Lereng (SF) pada *Inter-Ramp* Tengah 75
Gambar 5.18 Akurasi Hasil Model ANN pada *Inter-Ramp* Tengah 75
Gambar 5.19 Hasil Prediksi ANN Terhadap Optimalisasi Nilai Keamanan Lereng (SF) pada *Inter-Ramp* Bawah 77
Gambar 5.20 Akurasi Hasil Model ANN pada *Inter-Ramp* Bawah 77

DAFTAR TABEL

Tabel 2.1 Perbandingan Penelitian Terdahulu dan Penelitian Saat Ini 17

Tabel 3.1 Jenis Fungsi Aktivasi 32

Tabel 5.1 Parameter Tanah dan Lereng pada Lereng yang Ditinjau 61

Tabel 5.2 Rekapitulasi Nilai Keamanan Lereng (SF) dari Variasi Sudut Kemiringan Lereng (α) 20 – 50 derajat dengan Analisis Slope/W 65

Tabel 5.3 Rekapitulasi Hasil dari Optimalisasi Model ANN vs Analisis GeoStudio 78

Tabel 5.4 Rekapitulasi Akurasi Hasil Model ANN 78

Tabel 5.5 Rekapitulasi Arsitektural ANN 78

DAFTAR NOTASI DAN SINGKATAN

Adam = *Adaptive Moment Estimation*

ANN = *Artificial Neural Network*

MAPE = *Mean Absolute Percentage Error* (%)

MAT = Muka Air Tanah

MD = *Moment Driving* (kNm)

ML = *Machine Learning*

MLP = *Multilayer Perceptron*

MR = *Moment Resisting* (kNm)

R^2 = Koefisien Determinasi (%)

ReLU = *Rectified Linear Unit*

RMSE = *Root Mean Square Error* (satuan = variabel target)

SF = Nilai Keamanan Lereng

X_{max} = Nilai Maksimum dalam *Dataset*

X_{min} = Nilai Minimum dalam *Dataset*

α = Sudut Kemiringan Lereng (°)

a_i = Panjang Lengkung Lingkaran pada Irisan ke-i (m)

A_t = Target *Output* atau Nilai Aktual Data

b = Bias

c = Kohesi Tanah efektif (kN/m^2)

c_u = Kuat Geser *Undrained* Tanah di Bawah Lereng

F_t = *Output* Jaringan atau Nilai Hasil Prediksi

g (.) = Fungsi Aktivasi

H = Ketinggian Lereng (m)

n = Jumlah Irisan

n = Jumlah Data

q = Beban Merata (kN/m^2)

u = Potensi Aktivasi

u	= Tekanan Air Pori (kN/m^2)
W_i	= Berat Massa Tanah Irisan ke-i (kN/m^3)
w_i	= Bobot Sinapsis yang Terkait dengan *Input* ke-i
x	= Nilai Observasi
x_i	= Sinyal *Input* ke-i
y	= Sinyal *Output* yang Dihasilkan
θ	= Nilai Ambang Batas
θ_i	= Sudut yang Didefinisikan (°)
σ	= Deviasi Standar dari *Dataset*
μ	= Rata-Rata dari *Dataset*
φ	= Sudut Geser Dalam Tanah (°)
γ	= Berat Volume Tanah (kN/m^3)

ABSTRAK

Sektor pertambangan berperan penting dalam perekonomian di Indonesia, yang seringkali menghadapi tantangan terkait kestabilan lereng. Lereng yang tidak stabil dapat menyebabkan longsor yang merugikan dan membahayakan keselamatan banyak orang. Penelitian ini bertujuan untuk mengoptimalkan nilai keamanan lereng (SF) pada proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi menggunakan *Artificial Neural Network* (ANN) dengan pemrograman Python. Penelitian ini juga memberikan pertimbangan terkait efisiensi terhadap perencanaan tambang selanjutnya apabila ingin membuka galian tambang baru dengan mengurangi volume galian melalui penetapan sudut kemiringan dengan nilai keamanan lereng optimal yang ditargetkan.

Analisis dilakukan menggunakan data geoteknik seperti kohesi tanah, sudut geser dalam, berat volume tanah, serta parameter geometri lereng dengan membuat variasi model kemiringan lereng yang digunakan yakni 20 – 50 derajat dan dianalisis menggunakan *software* GeoStudio dengan metode Fellenius. Penggunaan ANN dengan pemrograman Python diterapkan untuk memprediksi nilai SF optimal dengan arsitektur *Multilayer Perceptron* (MLP), algoritma *backpropagation*, dan *hyperparameter* seperti ReLU dan Adam. Pelatihan dan pengujian dibagi menjadi 80% data latih dan 20% data uji secara *random* dan 100 *epochs*.

Hasil analisis menunjukkan nilai keamanan lereng memenuhi target syarat (SF $\geq$ 1.25) pada rentang kemiringan 20 – 47 derajat untuk *inter-ramp* atas, sementara *inter-ramp* tengah dan bawah memenuhi target SF pada semua variasi kemiringan. Hasil prediksi ANN menunjukkan kesesuaian dengan nilai aktual, terutama pada *inter-ramp* atas dengan SF 1.25 pada kemiringan 46,06 derajat, yang menghasilkan keakuratan dan kinerja model dengan hasil yang tinggi (loss 0,0008, MAE 0,0254 $\leq$ 0,1, RMSE 0,0285 $\leq$ 0,1 dan R^2 0,9 $\leq$ 0,9879 < 1).

Kata kunci: Artificial Neural Network, Nilai keamanan, Optimalisasi, Python

ABSTRACT

The mining sector plays a crucial role in the Indonesian economy but often faces challenges related to slope stability. Unstable slopes can lead to landslides, causing significant damage and endangering many lives. This research aims to optimize the slope safety factor (SF) at the PT Cipta Kridatama mining project in Tanjung Belit Village, Jambi Province, using an Artificial Neural Network (ANN) with Python programming. This study also provides efficiency considerations for future mine planning by reducing excavation volume through the determination of an optimal slope angle that meets the targeted safety factor.

The analysis was conducted using geotechnical data such as soil cohesion, internal friction angle, and soil unit weight, along with slope geometry parameters. Various slope angle models, ranging from 20 to 50 degrees, were created and analyzed using GeoStudio software with the Fellenius method. The ANN, implemented with Python, was used to predict the optimal SF value. It featured a Multilayer Perceptron (MLP) architecture, the backpropagation algorithm, and hyperparameters such as the ReLU activation function and the Adam optimizer. The dataset was randomly split into 80% for training and 20% for testing, with the model trained for 100 epochs.

The analysis results indicate that the safety factor meets the required target ($SF \geq 1.25$) for the upper inter-ramp within a slope range of 20 to 47 degrees. Meanwhile, the middle and lower inter-ramps met the target SF across all slope variations. The ANN's predictions showed a high degree of conformity with the actual values, particularly for the upper inter-ramp, which achieved an SF of 1.25 at a slope of 46.06 degrees. This demonstrates the model's high accuracy and performance, with a loss of 0.0008, MAE of 0.0254 (≤ 0.1), RMSE of 0.0285 (≤ 0.1), and an R^2 value of 0.9879 (where $0.9 \leq R^2 < 1$).

***Keywords**: Artificial Neural Network, Optimization, Python, Safety factor*

BAB I
PENDAHULUAN

1.1 Latar Belakang

Sektor pertambangan merupakan salah satu sektor yang sangat berperan penting dalam arus perekonomian Indonesia. Akan tetapi, kegiatan-kegiatan pada sektor pertambangan ini memiliki tantangan maupun resiko, salah satunya terkait dengan kestabilan lereng. Lereng yang tidak stabil akan menyebabkan bencana longsor yang berpotensi menimbulkan dampak negatif, seperti kerugian ekonomi, kerusakan lingkungan, dan juga ancaman terhadap keselamatan banyak orang. Oleh karena itu, nilai keamanan (*safety factor*) dari kestabilan lereng ini menjadi sangat penting untuk dilakukan pengoptimalan serta pertimbangan lebih lanjut. Selain itu, dengan adanya optimalisasi nilai keamanan lereng (SF) dengan mengetahui berapa sudut kemiringan lereng yang aman (tidak terlalu landai, akan tetapi masih tetap aman dari target syarat nilai keamanan yang digunakan) akan mempermudah proses perencanaan di kemudian hari apabila ingin membuka galian tambang baru dengan mengurangi volume galian.

PT Cipta Kridatama, sebagai salah satu perusahaan penyedia jasa pertambangan yang terkemuka di Indonesia yang berlokasi di Dusun Tanjung Belit, Provinsi Jambi, menghadapi tantangan yang serupa dalam perencanaan dan pelaksanaannya. Lokasi geografis dan juga keadaan geologis di lokasi pertambangan ini menarik perhatian yang lebih terhadap kestabilan lereng. Lokasi lereng yang ditinjau pada penelitian ini merupakan daerah yang dekat dengan daerah patahan (sesar) yang merupakan zona aktif (rawan pergerakan) dan terlebih, lokasi tinjauan juga pernah terjadi longsor pada tahun-tahun sebelumnya. Oleh karena itu, penelitian ini mengkaji ulang kemiringan lereng serta nilai keamanan lereng pada lokasi tersebut sebagai pertimbangan.

Analisis stabilitas lereng menggunakan metode konvensional tentu memerlukan waktu yang cukup lama dan juga data yang ekstensif yang dapat menghambat efisiensi operasional. Dengan perkembangan ilmu pengetahuan dan

teknologi yang semakin pesat, teknologi informasi maupun komputasi telah membuka peluang baru dalam bidang Teknik Sipil, termasuk penerapan kecerdasan buatan (*Artificial Intelligence*). Salah satu metode masa depan yang menjanjikan adalah penggunaan *Artificial Neural Network* (ANN), yang mampu memproses data dalam jumlah besar dan menemukan pola kompleks yang mungkin tidak dapat dilakukan dengan metode konvensional. ANN menawarkan potensi dalam meningkatkan efisiensi maupun akurasi dalam penilaian stabilitas lereng dengan memodelkan hubungan non-linear antara beberapa variabel menggunakan pemrograman Python. Penelitian ini bertujuan untuk mengoptimalkan nilai keamanan lereng yang ditinjau pada proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi dengan pemodelan ANN menggunakan pemrograman Python. Melalui pendekatan ini, diharapkan akan diperoleh model prediktif yang lebih akurat dan efisien, sehingga dapat mendukung pengambilan keputusan yang tepat terkait pengendalian resiko lereng dan mempermudah perencanaan pembukaan tambang selanjutnya. Selain itu, hasil penelitian ini diharapkan juga dapat memberikan kontribusi positif terhadap penerapan teknologi yang canggih dalam industri pertambangan di Indonesia, serta meningkatkan operasional pertambangan, keberlanjutan lingkungan maupun keselamatan pekerjaan.

Chen dkk. (2021) telah melakukan penelitian dalam mengeksplorasi dan mengintegrasikan penggunaan *Artificial Neural Network* (ANN) dalam model *ensemble* untuk memprediksi dan menganalisis kerentanan bencana tanah longsor. Penelitiannya yang berjudul "*Landslide Susceptibility Modeling Using Integrated Ensemble Weights of Evidence with Logistic Regression and Random Forest Models*" ini menunjukkan bahwa akurasi prediksi dari kerentanan tanah longsor dengan menggunakan ANN dan menggabungkannya dalam model *ensamble*, dapat digunakan dalam menangani kompleksitas dan non-linearitas dalam data geospasial maupun geoteknik melalui pendekatan berbagai algoritma. Chen dkk. (2021) mengembangkan model prediktif dengan mengumpulkan berbagai parameter dan variabel geoteknik yang tersedia, seperti data curah hujan, kemiringan lereng, jenis tanah, penggunaan lahan, dan juga jarak antara sungai dan jalan. Dalam melakukan

preprocessing data, data dinormalisasi terlebih dahulu untuk memastikan konsistensi dan mengurangi bias dalam analisis dengan membagi data menjadi set pelatihan (70%) dan pengujian (30%). Model *ensemble* yang didesain terdiri dari ANN, *Logistic Regression*, dan juga *Random Forest*, yang dimana ANN berfungsi untuk menangani hubungan non-linear dalam data, *Logistic Regression* berfungsi dalam menyediakan *baseline* prediksi dengan asumsi linearitas, serta *Random Forest* yang digunakan untuk menangani variabilitas data dan mengurangi *overfitting*. ANN kemudian dilakukan pelatihan model (*learning*) dengan *multilayer perceptron* (MLP) satu lapisan tersembunyi yang terdiri dari 10 neuron, serta *Logistic Regression* dan *Random Forest* dilatih menggunakan parameter *default* yang dioptimalkan melalui *cross-validation*. Hasil dari evaluasi pelatihannya berupa *Area Under Curve* (AUC) dari *Receiver Operating Characteristic* (ROC) yang selanjutnya digunakan untuk mengevaluasi kinerja model. Didapatkan melalui model *ensemble* menunjukkan AUC sebesar 0,91 yang memiliki kemampuan prediksi yang sangat baik. ANN sendiri menunjukkan AUC sebesar 0,89, yang lebih tinggi dibandingkan dengan *Logistic Regression* (AUC = 0,85) dan sebanding dengan *Random Forest* (AUC = 0,90). Integrasi ANN dalam model *ensemble* ini meningkatkan akurasi dan keandalan prediksi kerentanan tanah longsor dan menunjukkan penggunaan ANN dalam kombinasi dengan metode lain untuk pengaplikasian geoteknik memberikan pendekatan yang responsif maupun adaptif terhadap variabilitas dari lingkungan dan data geoteknik. Akan tetapi, keterbatasan dalam penelitian ini adalah ketergantungan yang cukup tinggi terhadap kualitas serta kuantitas data geospasial yang tersedia, sehingga menimbulkan resiko *overfitting* dalam model ANN yang kompleks dan model akan susah untuk digeneralisasi ke lokasi lain dengan kondisi geoteknik maupun lingkungan yang berbeda juga, misalnya model dapat menunjukkan peforma yang tinggi pada data pelatihan (AUC = 0,91) akan tetapi akan menurunkan akurasinya jika data pelatihan dilakukan di lokasi lain.

1.2 Rumusan Masalah

Berdasarkan latar belakang di atas, maka terdapat tiga rumusan masalah untuk optimalisasi nilai keamanan lereng (SF) pada proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi antara lain sebagai berikut.

1. Bagaimana nilai keamanan (SF) yang dihasilkan melalui analisis *software* stabilisasi lereng sebagai data aktual?
2. Bagaimana arsitektural ANN untuk mengetahui nilai keamanan (SF) yang optimal apabila digunakan variabel optimalisasi model?
3. Bagaimana akurasi penggunaan ANN terhadap nilai keamanan lereng (SF) yang optimal?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah di atas, maka tujuan penelitian ini adalah sebagai berikut.

1. Untuk mengetahui nilai keamanan (SF) yang dihasilkan melalui analisis *software* stabilisasi lereng sebagai data aktual.
2. Untuk mengetahui arsitektural ANN terhadap nilai keamanan (SF) yang optimal apabila digunakan variabel optimalisasi model.
3. Untuk mengetahui akurasi penggunaan ANN terhadap nilai keamanan lereng (SF) yang optimal.

1.4 Manfaat Penelitian

Adapun manfaat dari penelitian ini antara lain sebagai berikut.

1. Bagi Penulis, menambah pengetahuan dan pemahaman mengenai pentingnya mengetahui optimalisasi nilai keamanan pada lereng terutama di lokasi pertambangan yang seringkali dilewati oleh alat-alat berat tambang.
2. Perhitungan menjadi lebih efisien dengan menerapkan ANN dalam memprediksi atau mengoptimalisasi nilai keamanan lereng (SF).
3. Bagi Perusahaan atau perencana, untuk mengetahui berapa sudut kemiringan lereng yang aman dengan nilai keamanan lereng (SF) yang optimal (tidak terlalu landai, akan tetapi masih tetap aman dari target syarat nilai keamanan

yang digunakan) sebagai pertimbangan terkait tindakan pengambilan keputusan apabila terdapat lereng kritis karena akan membahayakan proyek dan banyak orang yang bekerja di lokasi pertambangan. Selain itu, dapat juga mempermudah proses perencanaan di kemudian hari apabila ingin membuka galian tambang baru dengan mengurangi volume galian.

1.5 Batasan Penelitian

Batasan penelitian penting untuk membatasi pembahasan, sehingga akan lebih fokus pada arah pembahasan. Adapun batasan penelitian ini adalah sebagai berikut.

1. Lokasi penelitian berada di proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi.
2. Analisis lereng hanya mengacu pada 1 potongan lereng di lokasi tinjauan penelitian yang berada di bagian *central* PIT proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi.
3. Nilai SF target atau syarat yang digunakan sebesar 1.25 yang mengacu pada persyaratan proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi.
4. Sudut kemiringan lereng yang divariasikan berada pada rentang 20 – 50 derajat yang mengacu pada persyaratan proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi.
5. Muka air tanah (MAT) didesain berada pada permukaan lereng atau dianggap berada pada kondisi terburuk (jenuh air).
6. Beban merata (q) yang digunakan merupakan alat berat tambang HD *Truck* 777 *Class*.
7. Stratigrafi atau lapisan lereng terdiri dari 3 batas jenjang (*inter-ramp*) berdasarkan dari ketinggian lapisannya.
8. *Environment* atau *requirements* yang digunakan yakni Anaconda 24.9.2 dengan bahasa pemrograman Python Interpreter 3.10.11.

BAB II
TINJAUAN PUSTAKA

2.1 Tinjauan Umum

Tinjauan pustaka penting untuk menyesuaikan teknik analisis yang tepat dengan data yang dikumpulkan dan menghindari duplikasi dari penelitian sebelumnya. Melalui tinjauan pustaka ini, dapat diperoleh gambaran yang jelas mengenai informasi yang relevan dengan penelitian saat ini, khususnya terkait penggunaan *Artificial Neural Network* dengan pemrograman Python untuk mengetahui optimalisasi nilai keamanan lereng (SF) di lokasi pertambangan, sehingga hal ini memungkinkan adanya perbedaan data lapangan dengan teori-teori yang ada.

Pemodelan ANN dengan menggunakan pemrograman Python dapat menyelesaikan masalah yang kompleks secara sistematis (Sarno dkk., 2021). Keakuratan metode ini bergantung pada tingkat korelasi antara data *input* dan *output* nya, karena ANN akan memproses informasi berdasarkan dari riwayat *input* yang diterimanya (Prathama dkk., 2021). Metode ini sangat dipengaruhi oleh nilai kuantitas maupun kualitas contoh atau data lapangan yang digunakan. Semakin banyak data lapangan dan contoh yang tersedia, maka akan semakin kecil pula kemungkinan atau resiko terjadinya kesalahan (Chollet, 2021). Metode ANN melibatkan beberapa tahapan seperti pemodelan, pelatihan, pengujian dan evaluasi model. Pada tahap pemodelan, maka perlunya analisis data, kemudian mengidentifikasi parameter yang akan digunakan, dan pemilihan dari bentuk jaringan atau *hyperparameter*. Tahap pelatihan ANN akan melibatkan persiapan data lapangan dan juga konfigurasi yang diperlukan untuk melakukan pelatihan. Kemudian, tahap pengujian ANN dilakukan untuk menguji dan memprediksi pelatihan yang telah dilakukan sebelumnya melalui perbandingan antara nilai aktual yang dibandingkan dengan hasil prediksi. Lalu tahap terakhir adalah mengevaluasi model yang akan menghasilkan perhitungan nilai *error* atau memberikan gambaran seberapa akurat model dalam membuat prediksi serta mencari model terbaik

berdasarkan keakuratan hasil prediksi dari beberapa model yang didapatkan (Sarker, 2021).

Penggunaan bahasa pemrograman Python dengan adanya berbagai Pustaka (*library*) dan perangkat lunaknya yang kuat, seperti *NumPy*, *SciPy*, ataupun *PySlope*, dapat digunakan untuk mengimplementasikan arsitektur ANN secara efisien dan akurat. Pada penelitian ini, penggunaan bahasa pemrograman Python akan memungkinkan dalam memodelkan, melatih, maupun menguji jaringan saraf secara lebih mudah, dan memanfaatkan kemampuannya dalam mengolah data-data yang besar maupun kompleks untuk meningkatkan hasil dari akurasi dan juga prediksi dengan membuat berbagai variasi skenario model serta menghitung dan menvisualisasikan nilai keamanan lereng (SF) yang optimal dari berbagai variasi sudut kemiringan yang tersedia, yang nantinya diharapkan melalui pendekatan ini dapat memberikan pertimbangan atau rekomendasi yang tepat terkait pengambilan keputusan dan proses perencanaan pembukaan galian tambang baru.

Pada bab ini, akan diuraikan bagaimana penelitian-penelitian terdahulu yang memiliki kaitannya dengan penelitian yang dilakukan, serta perbedaan-perbedaan yang ada tentang optimalisasi nilai keamanan lereng (SF) pada proyek pertambangan menggunakan Artificial Neural Network (ANN).

2.2 Penelitian Terdahulu

Penelitian terdahulu dilakukan agar penelitian ini mendapatkan literatur yang mungkin bisa menjadi acuan atau dasar yang relevan dengan penelitian-penelitian yang pernah ada dan dapat memperkaya teori serta menjadi pembanding.

2.2.1 Analisis Stabilitas Lereng

1. Metode *Fellenius* dan dan Metode *Bishop*

   Penelitian yang dilakukan oleh Nugroho dan Hargiono (2021) yang berjudul Analisis Stabilitas Lereng pada Area Penambangan Batugamping di PT. Semen Gresik Pabrik Rembang, yang menganalisis kestabilan lereng penambangan dengan menggunakan beberapa metode kesetimbangan batas, yakni metode *Fellenius* dan *Bishop*. Data pada penelitian ini menggunakan data primer yang diperoleh melalui observasi dan pengukuran langsung di

lapangan, seperti pengukuran geometri lereng (tinggi, sudut kemiringan, dan lebar jenjang) menggunakan alat survei. Data sekunder mencakup data sifat fisik dan mekanik batuan yang diperoleh dari laporan penyelidikan geoteknik sebelumnya atau pengujian laboratorium. Parameter yang dikumpulkan meliputi kohesi (c), sudut geser dalam (φ), dan berat volume batuan (γ). Selanjutnya, data geometri yang telah dikumpulkan kemudian digunakan untuk membuat model penampang lereng dua dimensi. Pada penelitian ini, lereng dimodelkan dengan menggunakan perangkat lunak geoteknik yakni Rocscience Slide dengan ketinggian lereng 15 meter dan sudut kemiringan lereng 60°. Nilai parameter yang digunakan adalah nilai kohesi (c) sebesar 2.8 ton/m², sudut geser dalam (φ) sebesar 35°, dan berat volume (γ) sebesar 2.4 ton/m³. Kemudian, pencarian dilakukan dengan metode *grid and radius* serta *entry and exit* yang mensimulasikan ribuan kemungkinan busur lingkaran bidang gelincir. Hasil menunjukkan perbedaan nilai keamanan lereng (SF) yang signifikan dimana metode *Fellenius* menghasilkan SF sebesar 1.355, sedangkan metode *Bishop* menghasilkan SF sebesar 1.533. Nilai keamanan ini secara kuantitatif membuktikan bahwa metode *Fellenius* lebih konservatif yang memberikan nilai SF sekitar 13% lebih rendah dari metode *Bishop*. Hal ini dikarenakan metode *Bishop* melakukan perhitungan yang lebih kompleks dan bersifat iteratif, karena memperhitungkan gaya normal antar irisan. Sedangkan, metode *Fellenius* melakukan perhitungan dengan menjumlahkan gaya-gaya penahan (dari kohesi dan gesekan) di sepanjang dasar setiap irisan dan membaginya dengan jumlah gaya-gaya penggerak (dari berat irisan), dan mengabaikan semua gaya antar irisan. Metode *Fellenius* sensitif terhadap gaya normal, sehingga dapat menyebabkan nilai keamanan yang lebih konservatif karena hanya memenuhi kesetimbangan momen, dimana dalam konteks pertambangan, konsekuensi lereng yang gagal atau longsor akan sangat berakibat fatal sehingga pendekatan yang terlalu optimis bisa berbahaya.

Sehingga pada penelitian ini, digunakan metode yang memberikan estimasi dengan resiko terburuk yang dapat terjadi (*Fellenius*) pada perhitungan

analisis stabilisasi lereng yang dapat dengan cepat dalam mengidentifikasi lereng-lereng yang berpotensi kritis tanpa memerlukan analisis iteratif yang rumit. Dengan demikian, keunggulan metode *Fellenius* ini tidak terletak pada presisi numeriknya, melainkan pada perannya sebagai sistem peringatan dini yang efektif, sederhana, dan sangat berhati-hati (*highly conservative*), yang sesuai dengan penelitian ini dimana SF yang menjadi target atau syarat yang akan dilakukan optimalisasi adalah SF yang mengarah pada 1.25.

2.2.2 Prediksi Stabilitas Lereng dengan *Machine Learning* (ML)

1. *Artificial Neural Network* (ANN)

Penelitian yang dilakukan oleh Khan dkk. (2020) dalam jurnal nya yang berjudul *Application of Artificial Neural Networks for Slope Stability Analysis: A Comparative Study with Traditional Methods*, yang mengembangkan model ANN dalam memprediksi nilai kemanan lereng. Khan dkk. (2020) menemukan bahwa ANN memiliki kemampuan dalam belajar dari data-data geometri lereng yang lebih historis dan cepat dalam mengadaptasi modelnya berdasarkan pola yang ada, sehingga menghasilkan prediksi yang lebih baik dalam situasi yang lebih kompleks. ANN juga dapat mengurangi waktu yang dibutuhkan dalam analisis karena pelatihannya yang dilakukan akan dapat memproses data *output* atau hasil dengan cepat tanpa perlu melakukan perhitungan yang rumit seperti pada metode-metode konvensional. Khan dkk. (2020) juga menemukan bahwa dalam penerapannya, penggunaan ANN memberikan fleksibilitas yang lebih besar dalam menangani variasi data geometri lereng yang berbeda dalam analisis stabilitas lereng, yang dimana ini seringkali menjadi tantangan tersendiri dalam metode konvensional. Oleh karena itu, pada penelitian ini digunakan model dengan pendekatan ANN yang memiliki kemampuan yang sangat baik dalam menangkap hubungan non-linear antara variabel *input* dan juga *output* nantinya yang dihasilkan dalam memprediksi nilai keamanan lereng (SF) pada proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi.

2. *Machine Learning in the Stochastic Analysis of Slope Stability: A State-of-the-Art Review*

Penelitian yang berjudul *Machine Learning in the Stochastic Analysis of Slope Stability: A State-of-the-Art Review* yang ditulis oleh Hoading dkk. (2023) ini mengkaji 159 studi yang berfokus pada penggunaan teknik pembelajaran yang terawasi seperti contohnya *Artificial Neural Network* (ANN), *Support Vector Machines* (SVM), dan *Gaussian Process Regression* (GPR), untuk memprediksi nilai keamanan lereng (SF). Hasil analisis tersebut menunjukkan bahwa metode-metode ini tidak hanya mampu memberikan akurasi yang tinggi dalam memprediksi SF, akan tetapi juga dapat menangani kompleksitas dan juga variabilitas data. Beberapa studi dari penelitian ini menunjukkan nilai R^2 di atas 0,9 yang berarti menunjukkan bahwa model yang dibangun memiliki hubungan yang sangat baik antara variabel *input* dan *output*. Ini berarti menunjukkan bahwa pelatihan ANN yang dilakukan sangat efektif dalam memprediksi kestabilan lereng dan pengolahan data dalam jumlah yang besar dan beragam. Penelitian ini juga menggunakan teknik *hyperparameter optimization* dan *ensamble learning* yang digunakan dalam teknik pengolahan data untuk meningkatkan akurasi prediksi dari performa model. Akan tetapi, penelitian ini hanya berfokus kepada penerapan metode pembelajaran mesin tanpa memberikan cukup fokus pada nilai keamanan lereng ataupun integrasi metode konvensional yang digunakan sehingga analisis menjadi probabilistik. Dengan penelitian saat ini, pendekatan yang dilakukan adalah dengan mengoptimalkan nilai keamanan lereng (SF) dengan melakukan pemodelan ANN dengan menggunakan pemrograman Python yang memungkinkan penggunaan teknik analisis yang beragam dari metode konvensional lalu kemudian diolah dengan adanya pelatihan dari ANN, sehingga evaluasi kinerja model akan dilakukan secara lebih menyeluruh dan meningkatkan kecepatan maupun efektivitas dari hasil analisis.

3. Analisis Kestabilan Lereng Menggunakan *Artificial Neural Network*

Penelitian yang berjudul Analisis Kestabilan Lereng Menggunakan *Artificial Neural Network* yang dilakukan oleh Hidayat dkk. (2022) ini

meninjau penggunaan *Artificial Neural Network* (ANN) dalam analisis kestabilan lereng, terutama dalam konteks pertambangan. Hasilnya menunjukkan bahwa ANN memberikan hasil yang mendekati hasil analisis metode empiris. Dalam penelitian ini, pemodelan ANN yang digunakan adalah satu *hidden layer* dan algoritma pembelajaran *backpropagation* (BP) menjadi pilihan utama dalam menyelesaikan masalah prediksi maupun klasifikasinya. Parameter yang digunakan juga menggunakan tambahan dari kondisi pelapukan (WEATH). Kemudian, penelitian ini memberikan hasil analisis yang menunjukkan nilai R^2 yang tinggi, dengan beberapa model mendapati R^2 = 0,999, yang dimana menunjukkan akurasi yang baik dalam memprediksi nilai keamanan lereng. Namun, meskipun penggunaan ANN dalam penelitian ini menunjukkan keunggulan dalam hal fleksibilitas dan kemampuannya dengan data baru, tetapi kurangnya transparansi dalam pemodelan ANN yang digunakan dan sulit dipahami oleh pengguna. Dengan adanya bantuan dari pemrograman Python pada penelitian saat ini, diharapkan dapat mengatasi masalah tersebut dengan arah visualisasi yang jelas dan tergambar lewat grafik sehingga pengguna dapat lebih memahami dan memanfaatkan model yang dihasilkan dengan pengkodingan dan validasi dari model yang beragam yang disediakan di lapangan.

2.2.3 Optimalisasi Nilai Keamanan Lereng (SF) dengan Pemodelan *Artificial Neural Network* (ANN)

1. *A Predictive Model Based on An Optimized ANN Combined with ICA for Predicting the Stability of Slopes*

   Penelitian yang berjudul *A Predictive Model Based on An Optimized ANN Combined with ICA for Predicting the Stability of Slopes* oleh Gao dkk. (2019) ini meneliti penggunaan jaringan saraf tiruan (ANN) yang kemudian dioptimalkan dengan algoritma *Imperialist Competitive Algorithm* (ICA) untuk memprediksi stabilitas lereng pada tanah kohesif. Data pelatihan dan pengujian dikumpulkan dari berbagai simulasi analisis keseimbangan limit, yang kemudian dijalankan dengan perangkat lunak OptumG2. Hasil

menunjukkan bahwa model ICA-ANN lebih akurat memprediksi angka stabilitas tak berdimensi (N2c) dibandingkan dengan model ANN biasa. Model ICA-ANN mencapai nilai R^2 sebesar 0,9999 dan RMSE sebesar 0,0107 untuk data pelatihan dan R^2 sebesar 0,9991 dan RMSE sebesar 0,0102 untuk data pengujian pada analisis limit batas bawah. Hal ini tentu akan sama dengan penelitian saat ini yang dimana sama-sama menggunakan ANN untuk mengoptimalkan nilai keamanan (SF) dari lereng. Akan tetapi, untuk penelitian saat ini menggunakan bahasa pemrograman Python sebagai dukungan pengembangan dalam pengoptimalan ANN. Hal ini dikarenakan penerapan ICA-ANN pada penelitian ini memiliki keterbatasan dalam memperluas cakupan data dengan informasi kondisi geologi yang berbeda.

2. *Novel Approach to Efficient Slope Reliability Analysis in Spatially Variabels Soils*

Penelitian yang berjudul *Novel Approach to Efficient Slope Reliability Analysis in Spatially Variabels Soils* oleh Wang dan Goh. (2021) ini menunjukkan bagaimana penggunaan *Convolutional Neural Network* (CNN) sebagai model yang digunakan untuk keandalan lereng dalam tanah yang bervariasi secara spasial dapat memberikan hasil yang efisien dan akurat. Dalam penelitian ini, metode *Random Field Finite Element Method* (RF-FEM) digunakan untuk menganalisis stabilitas lereng dengan mempertimbangkan variabel spasial dari sifat tanah yang dimana menunjukkan bahwa pendekatan CNN dapat memprediksi probabilitas kegagalan lereng dengan akurasi dalam 5% dari nilai yang diperoleh malalui simulasi Monte Carlo langsung. Dalam penelitian yang dilakukan, probabilitas kegagalan lereng yang dihasilkan adalah 3% dengan koefisien variasi (COV) dari probabilitas mencapai 27%. Penelitian ini juga menunjukkan bahwa hanya diperlukan 400 simulasi Monte Carlo untuk melatih CNN, setelah itu jaringan yang terlatih akan dapat digunakan untuk melakukan ribuan simulasi. Akan tetapi, penelitian ini tidak praktis dalam pengaplikasiannya dan memerlukan waktu maupun sumber daya yang sangat banyak. Oleh karena itu, penerapan pemodelan ANN dengan pemrograman

Python dapat memberikan kemudahan fleksibilitas dalam pengolahan data maupun prediksi tanpa membutuhkan waktu yang banyak dan model yang lebih kompleks.

2.2.4 Penerapan Pemodelan *Artificial Neural Network* (ANN) dengan Bahasa Pemrograman Python

1. Optimalisasi Beton Prategang PCI Girder pada Jembatan Perning Kloji, Mojokerto Menggunakan Metode *Artificial Neural Network*

Penelitian yang berjudul Optimalisasi Beton Prategang PCI Girder pada Jembatan Perning Kloji, Mojokerto Menggunakan Metode *Artificial Neural Network* oleh Maji'Aturrohmah (2024) ini menunjukkan penggunaan dan pengembangan model ANN dalam penerapannya. Penelitian ini dilakukan karena jembatan tersebut dianggap tidak layak pakai akibat pergeseran salah satu pilar, sehingga perlu dilakukan penggantian dengan struktur yang lebih efisien dan ekonomis.

Setelah dilakukan analisis pembebanan, dilakukan pemodelan struktur dengan 150 variasi percobaan (*trial*) untuk memenuhi syarat desain, seperti lendutan, tegangan momen, dan tegangan geser. Data dari percobaan ini kemudian digunakan sebagai *input* untuk pemrograman ANN. Pemrograman ANN dilakukan menggunakan *software* MATLAB dengan algoritma *backpropagation* (BP). *Input* yang digunakan dalam pemrograman ANN meliputi panjang bentang, mutu beton, mutu baja, diameter *strand*, jumlah *strand*, jarak antar gelagar, dan jumlah gelagar. Sedangkan *output* yang dihasilkan adalah tinggi girder, momen, gaya geser, dan biaya konstruksi.

Hasil dari pemrograman ANN menunjukkan bahwa desain PCI Girder yang optimal memiliki tinggi girder 2,3 m, mutu beton 68,60 MPa, diameter *strand* 7,94 mm, jarak antar gelagar 1.500 mm, dan jumlah gelagar 6 buah. Adapun biaya konstruksi yang dihasilkan dari desain ini adalah Rp905.184.683,36, yang dimana biaya tersebut lebih murah 20,13% dibandingkan dengan biaya desain *eksisting* sebesar Rp1.133.300.230,21.

Selain itu, hasil prediksi ANN juga divalidasi dengan perhitungan manual menggunakan rumus empiris, dan ditemukan bahwa *error* antara hasil prediksi ANN dengan perhitungan manual adalah 7,56%, yang masih dalam batas aman karena kurang dari 10%.

2. Optimasi Proporsi Bahan Substitusi Dalam Campuran Beton Terhadap Kuat Tekan Menggunakan Metode *Artificial Neural Network*

Penelitian yang berjudul Optimasi Proporsi Bahan Substitusi Dalam Campuran Beton Terhadap Kuat Tekan Menggunakan Metode *Artificial Neural Network* oleh Hibatulloh, M. (2024) ini bertujuan dalam pengoptimalan proporsi bahan substitusi dalam campuran beton terhadap kuat tekan dengan memanfaatkan *dataset* dari UCI *Machine Learning Repository* yang berisi informasi tentang komposisi bahan penyusun beton, termasuk bahan substitusi seperti *fly ash*, *superplasticizer*, dan *blast furnace slag*, serta umur pengujian dan kuat tekan beton. *Dataset* ini digunakan untuk melatih model ANN yang kemudian diaplikasikan untuk memprediksi kuat tekan beton dan menentukan proporsi bahan substitusi yang optimal.

Pemodelan ANN dalam penelitian ini dilakukan menggunakan bahasa pemrograman Python dengan bantuan *library* seperti *TensorFlow* dan *Keras*. Model ANN yang digunakan dalam penelitian ini terdiri dari *input layer, hidden layer*, dan *output* layer. *Input* layer terdiri dari variabel-variabel seperti semen, air, agregat kasar, agregat halus, *fly ash, superplasticizer, blast furnace slag,* dan umur pengujian beton. *Output* layer sendiri merupakan kuat tekan beton.

Kemudian model ANN dievaluasi menggunakan metrik *Root Mean Square Error* (RMSE), koefisien determinasi (R^2), dan *Mean Absolute Percentage Error* (MAPE). Model terbaik yang dihasilkan memiliki nilai RMSE sebesar 3,98 MPa, R^2 sebesar 0,92, dan MAPE sebesar 8,53%. Nilai-nilai ini menunjukkan bahwa model ANN memiliki kemampuan prediksi yang baik dengan tingkat akurasi yang tinggi. Setelah model ANN divalidasi, model tersebut digunakan untuk mengoptimalisasi proporsi bahan substitusi dalam campuran beton. Variasi proporsi bahan substitusi yang diuji

meliputi: *fly ash* 0% - 50% dari berat semen, *superplasticizer* 0% - 1% dari berat semen, dan *blast furnace slag* 0% - 50% dari berat semen.

Hasil optimalisasi menunjukkan bahwa proporsi optimal untuk *fly ash* adalah 18,9% pada umur beton 28 hari, dengan peningkatan kuat tekan sebesar 21,83% ketika digunakan bersama *superplasticizer* 1% pada proporsi *fly ash* 24,1%. Untuk *superplasticizer*, proporsi optimal adalah 1%, dengan peningkatan kuat tekan sebesar 35,71% pada umur 14 hari. Sementara itu, proporsi optimal untuk *blast furnace slag* adalah 22,8%, dengan kuat tekan maksimum 43,29 MPa pada umur 28 hari.

3. Penerapan *Artificial Neural Network* Sebagai Upaya Optimalisasi Struktur Kolom pada Proyek Perluasan Lombok Epicentrum Mall dan Podium Parkir

Penelitian yang berjudul Penerapan *Artificial Neural Network* Sebagai Upaya Optimalisasi Struktur Kolom pada Proyek Perluasan Lombok Epicentrum Mall dan Podium Parkir oleh Syafiq, A. (2024) ini bertujuan untuk mengoptimalkan desain struktur kolom dengan menggunakan metode Artificial Neural Network (ANN), sehingga dapat menghasilkan struktur yang lebih efisien dan ekonomis tanpa mengorbankan kekuatan dan keamanan struktur. Penelitian ini menggunakan MATLAB sebagai alat bantu untuk pemodelan ANN, namun konsep dan metodologi yang digunakan dapat diterapkan juga dalam pemrograman Python dengan menggunakan pustaka (*library*) seperti *TensorFlow*, *Keras*, atau *PyTorch*. ANN digunakan untuk memprediksi dimensi optimal kolom, rasio tulangan, dan biaya pekerjaan kolom berdasarkan variabel *input* seperti mutu beton, mutu baja, diameter tulangan, gaya aksial, dan momen yang bekerja pada kolom. Proses pemodelan ANN dimulai dengan mengumpulkan data dari empat model percobaan (*trial*) yang telah dianalisis sebelumnya. Data ini mencakup variabel *input* seperti mutu beton (f'c), mutu baja tulangan (fy), diameter tulangan, gaya aksial (Pu), momen (Mux, Muy), dan variabel *output* seperti lebar kolom (B), tebal kolom (H), rasio tulangan (ρ), jarak tulangan transversal (St), dan biaya pekerjaan kolom (C). Data ini kemudian

dinormalisasi untuk memastikan bahwa model ANN dapat mengenali pola dengan baik.

Proses pemodelan ANN dimulai dengan memasukkan dan normalisasi data *input* dan *output* untuk memastikan bahwa semua variabel memiliki skala yang sama, sehingga proses pelatihan model ANN dapat berjalan lebih efektif. Model ANN dibentuk dengan beberapa lapisan (*layer*) yang terdiri dari *input layer*, *hidden layer*, dan *output layer*. Fungsi aktivasi yang digunakan adalah Log-Sigmoid untuk *hidden layer* dan linear untuk *output layer*. Model ANN dilatih menggunakan algoritma *backpropagation* (BP) untuk meminimalkan *error* antara prediksi dan nilai aktual. Data dibagi menjadi dua bagian, yaitu data pelatihan (*training data*) dan data pengujian (*testing data*). Setelah model dilatih, dilakukan pengujian untuk memvalidasi akurasi model dengan membandingkan hasil prediksi dengan data aktual.

Hasil dari penelitian ini menunjukkan bahwa model ANN mampu memprediksi dimensi dan biaya pekerjaan kolom dengan akurasi yang tinggi. Berdasarkan hasil optimalisasi, biaya pekerjaan kolom yang diperlukan setelah menggunakan model ANN adalah Rp10.747.790.267, sedangkan biaya terendah dari empat model *trial* adalah Rp12.169.806.672 (pada model *trial* 1). Ini menunjukkan bahwa model ANN berhasil mengoptimalkan biaya pekerjaan kolom dengan pengurangan biaya sebesar 11,68%. Selain itu, nilai *error* antara biaya prediksi berdasarkan rumus empiris yang dihasilkan oleh ANN dengan biaya aktual adalah 1,78%, yang menunjukkan bahwa prediksi yang dihasilkan oleh model ANN sangat akurat. Model ANN juga berhasil memenuhi persyaratan struktur seperti *drift ratio*, *p-delta effect*, dan ketidakberaturan torsi, sehingga struktur hasil optimalisasi dapat dianggap aman dan efisien.

2.3 Perbandingan Penelitian Dahulu dan Penelitian Saat Ini

Berikut merupakan uraian mengenai perbedaan – perbedaan yang terdapat pada penelitian terdahulu dengan penelitian saat ini yang dilakukan, dapat dilihat pada Tabel 2.1 sebagai berikut.

Tabel 2.1 Perbandingan Penelitian Terdahulu dan Penelitian Saat Ini

Penulis / Parameter	Khan dkk. (2020)	Hoading dkk. (2023)	Hidayat dkk. (2022)
Judul Penelitian	*Application of Artificial Neural Networks for Slope Stability Analysis: A Comparative Study with Traditional Methods*	*Machine Learning in the Stochastic Analysis of Slope Stability: A State-of-the-Art Review*	Analisis Kestabilan Lereng Menggunakan *Artificial Neural Network*
Lokasi Penelitian	Noabad, Mazandaran, Iran	University of Technology Sydney, Australia	-
Metode dan Tahap Penelitian	Khan dkk. (2020) menemukan bahwa ANN memiliki kemampuan dalam belajar dari data-data geometri lereng yang lebih historis dan cepat dalam mengadaptasi modelnya berdasarkan pola yang ada, sehingga menghasilkan prediksi yang lebih baik dalam situasi yang lebih kompleks.	Mengkaji 159 studi yang berfokus pada penggunaan teknik pembelajaran yang terawasi seperti contohnya *Artificial Neural Network* (ANN), *Support Vector Machines* (SVM), dan *Gaussian Process Regression* (GPR), untuk memperdiksi nilai keamanan dari lereng (SF). Penelitian ini juga menggunakan teknik *hyperparameter optimization* dan *ensamble learning* yang digunakan dalam teknik pengolahan data untuk meningkatkan akurasi prediksi dari performa model.	Meninjau penggunaan *Artificial Neural Network* (ANN) dalam analisis kestabilan lereng, terutama dalam konteks pertambangan.
Hasil Penelitian	ANN memberikan fleksibilitas yang lebih besar dalam menangani variasi data geometri lereng yang berbeda dalam analisis stabilitas lereng, yang dimana ini seringkali menjadi tantangan tersendiri dalam metode konvensional. Pada penelitian ini digunakan model dengan pendekatan metode ANN yang memiliki kemampuan yang sangat baik dalam menangkap hubungan non-linear antara variabel *input* dan juga *output* nantinya yang dihasilkan dalam memprediksi nilai keamanan stabilitas lereng.	Metode-metode ini tidak hanya mampu memberikan akurasi yang tinggi dalam memprediksi nilai SF, akan tetapi juga dapat menangani kompleksitas dan juga variabilitas data. Beberapa studi dari penelitian ini menunjukkan nilai R^2 di atas 0,9 yang berarti menunjukkan bahwa model yang dibangun memiliki hubungan yang sangat baik antara variabel *input* dan *output*. Ini berarti menunjukkan bahwa pelatihan ANN yang dilakukan sangat efektif dalam memprediksi kestabilan lereng dan pengolahan data dalam jumlah yang besar dan beragam.	ANN memberikan hasil yang mendekati hasil analisis metode empiris. Dalam penelitian ini, pemodelan ANN yang digunakan adalah satu *hidden layer* dan algoritma pembelajaran *backpropagation* (BP) menjadi pilihan utama dalam menyelesaikan masalah prediksi. Parameter yang digunakan juga menggunakan tambahan dari kondisi pelapukan (WEATH). Kemudian, penelitian ini memberikan hasil analisis yang menunjukkan nilai R^2 yang tinggi, dengan beberapa model mendapati R^2 = 0,999, dimana menunjukkan akurasi yang baik dalam memprediksi nilai keamanan lereng (SF).

Lanjutan Tabel 2.1 Perbandingan Penelitian Terdahulu dan Penelitian Saat Ini

Penulis / Parameter	Gao dkk. (2019)	Wang dan Goh. (2021)	Maji'Aturrohmah (2024)
Judul Penelitian	*A Predictive Model Based on An Optimized ANN Combined with ICA for Predicting the Stability of Slopes*	*Novel Approach to Efficient Slope Reliability Analysis in Spatially Variabels Soils*	Optimalisasi Beton Prategang PCI Girder pada Jembatan Perning Kloji, Mojokerto Menggunakan Menggunakan Metode *Artificial Neural Network*
Lokasi Penelitian	-	-	Jembatan Perning Kloji, Mojokerto
Metode dan Tahap Penelitian	Gao dkk. (2019) meneliti penggunaan jaringan saraf tiruan (ANN) yang kemudian dioptimalkan dengan algoritma *Imperialist Competitive Algorithm* (ICA) untuk memprediksi stabilitas lereng pada tanah kohesif. Data pelatihan dan pengujian dikumpulkan dari berbagai simulasi analisis keseimbangan limit, yang kemudian dijalankan dengan perangkat lunak OptumG2.	Metode *Random Field Finite Element Method* (RF-FEM) digunakan untuk menganalisis stabilitas lereng dengan mempertimbangkan variabel spasial dari sifat tanah yang dimana menunjukkan bahwa pendekatan CNN dapat memprediksi probabilitas kegagalan lereng dengan akurasi dalam 5% dari nilai yang diperoleh malalui simulasi Monte Carlo langsung.	Pemodelan struktur dengan 150 variasi percobaan (*trial*) untuk memenuhi syarat desain, seperti lendutan, tegangan momen, dan tegangan geser. Data dari percobaan ini kemudian digunakan sebagai *input* untuk pemrograman ANN. Pemrograman ANN dilakukan menggunakan *software* MATLAB dengan algoritma *backpropagation*. *Input* yang digunakan dalam pemrograman ANN meliputi panjang bentang, mutu beton, mutu baja, diameter *strand*, jumlah *strand*, jarak antar gelagar, dan jumlah gelagar. Sedangkan *output* yang dihasilkan adalah tinggi girder, momen, gaya geser, dan biaya konstruksi.
Hasil Penelitian	Hasil menunjukkan bahwa model ICA-ANN lebih akurat memprediksi angka stabilitas tak berdimensi (N2c) dibandingkan dengan model ANN biasa.	Dalam penelitian yang dilakukan, probabilitas kegagalan lereng yang dihasilkan adalah 3% dengan koefisien variasi (COV) dari probabilitas mencapai 27%. Penelitian ini juga menunjukkan bahwa hanya diperlukan 400 simulasi Monte Carlo untuk melatih CNN, setelah itu jaringan yang terlatih akan dapat digunakan untuk melakukan ribuan simulasi.	Hasil dari pemrograman ANN menunjukkan bahwa desain PCI girder yang optimal memiliki tinggi girder 2,3 m, mutu beton 68,60 MPa, diameter *strand* 7,94 mm, jarak antar gelagar 1.500 mm, dan jumlah gelagar 6 buah. Adapun biaya konstruksi yang dihasilkan dari desain adalah Rp905.184.683,36, dimana biaya tersebut lebih murah 20,13% dibandingkan dengan biaya desain *eksisting* sebesar Rp1.133.300.230,21. ANN memprediksi dengan validasi *error* 7,56% yang masih batas aman karena kurang dari 10%.

Lanjutan Tabel 2.1 Perbandingan Penelitian Terdahulu dan Penelitian Saat Ini

Penulis / Parameter	Hibatulloh, M. (2024)	Syafiq, A. (2024)	Penulis (2025)
Judul Penelitian	Optimasi Proporsi Bahan Substitusi Dalam Campuran Beton Terhadap Kuat Tekan Menggunakan Metode *Artificial Neural Network*	Penerapan *Artificial Neural Network* Sebagai Upaya Optimalisasi Struktur Kolom pada Proyek Perluasan Lombok Epicentrum Mall dan Podium Parkir	Optimalisasi Nilai Keamanan Lereng pada Pertambangan di Dusun Tanjung Belit, Provinsi Jambi Menggunakan Artificial Neural Network
Lokasi Penelitian	-	Proyek Perluasan Lombok Epicentrum Mall dan Podium Parkir	Proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi
Metode dan Tahap Penelitian	Memanfaatkan *dataset* dari UCI *Machine Learning Repository* yang berisi informasi tentang komposisi bahan penyusun beton, termasuk bahan substitusi seperti *fly ash*, *superplasticizer*, dan *blast furnace slag*, serta umur pengujian dan kuat tekan beton. *Dataset* ini digunakan untuk melatih model ANN yang kemudian diaplikasikan untuk memprediksi kuat tekan beton dan menentukan proporsi bahan substitusi yang optimal. Pemodelan ANN dalam penelitian ini dilakukan menggunakan bahasa pemrograman Python dengan bantuan *library* seperti *TensorFlow* dan *Keras*. Model ANN yang digunakan dalam penelitian ini terdiri dari *input layer*, *hidden layer*, dan *output layer*. *Input layer* terdiri dari variabel-variabel seperti semen, air, agregat kasar, agregat halus, *fly ash, superplasticizer, blast furnace slag,* dan umur pengujian beton. *Output layer* adalah kuat tekan beton. Model ANN dievaluasi menggunakan metrik *Root Mean Square Error* (RMSE), Koefisien Determinasi (R^2), dan *Mean Absolute Percentage Error* (MAPE).	Menggunakan MATLAB sebagai alat bantu untuk pemodelan ANN, namun konsep dan metodologi yang digunakan dapat diterapkan juga dalam Python dengan menggunakan *library* seperti *TensorFlow*, *Keras*, atau *PyTorch*. ANN digunakan untuk memprediksi dimensi optimal kolom, rasio tulangan, dan biaya pekerjaan kolom berdasarkan variabel *input* seperti mutu beton, mutu baja, diameter tulangan, gaya aksial, dan momen yang bekerja pada kolom. Model ANN dibentuk dengan beberapa lapisan (*layer*) yang terdiri dari *input layer, hidden layer*, dan *output layer*. Model ANN dilatih menggunakan algoritma *backpropagation* untuk meminimalkan *error* antara prediksi dan nilai aktual. Data dibagi menjadi dua bagian, yaitu data pelatihan (*training data*) dan data pengujian (*testing data*). Setelah model dilatih, dilakukan pengujian untuk memvalidasi akurasi model dengan membandingkan hasil prediksi dengan data aktual.	Metode *Fellenius (Ordinary)* dan pemodelan *Artificial Neural Network* dengan pemrograman Python. Tahap penelitian yang dilakukan adalah dengan analisis data-data geometri lereng atau tanah, model dibuat dengan variasi sudut kemiringan lereng (α) yang mengacu pada prinsip nilai keamanan lereng (SF) dan persyaratan yang digunakan di proyek pertambangan PT Cipta Kridatama, Jambi, dimana parameter-parameter tanah dan lereng serta model yang divariasikan tersebut akan dianalisis dengan *software* GeoStudio (*Slope/W*) melalui pendekatan keseimbangan batas (*limit equilibrium*) menggunakan metode *Fellenius* yang nantinya akan memberikan hasil dan gambaran bidang gelincir serta nilai keamanan lereng (SF). *Software Visual Studio Code* digunakan sebagai *platform* dalam pemodelan ANN dengan pemrograman Python dan *environment* Anaconda. Tahap selanjutnya adalah pengembangan dan proses pelatihan model ANN. Pelatihan dan penguujian model dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian secara *random*. Arsitektur ANN terdiri dari 1 *input layer* yang terdiri dari 7 parameter himpunan data *input*, 3 *hidden layers*, yang dimana setiap *hidden layers* terdiri dari

Lanjutan Tabel 2.1 Perbandingan Penelitian Terdahulu dan Penelitian Saat Ini

Penulis / Parameter	Hibatulloh, M. (2024)	Syafiq, A. (2024)	Penulis (2025)
Metode dan Tahap Penelitian			sejumlah neuron yang masing-masing melakukan perhitungan berbasis bobot dan bias. *Hidden layer* 1 memiliki 30 neuron, *hidden layer* 2 memiliki 20 neuron, dan *hidden layer* 3 memiliki 10 neuron dengan fungsi aktivasi ReLU. Kemudian pada o*utput* layer terdiri dari 1 neuron karena fungsi dan tugasnya untuk regresi. Adapun *output* yang ingin dihasilkan adalah nilai keamanan lereng (SF) optimal yang mendekati SF 1.25 sesuai dengan SF target atau syarat yang digunakan. Setelah model ANN dilatih, model kemudian diuji dan dievaluasi. Selanjutnya akan dicari model terbaik yang akan digunakan dan menjadi pertimbangan.
Hasil Penelitian	Hasil optimasi menunjukkan bahwa proporsi optimal untuk *fly ash* adalah 18,9% pada umur beton 28 hari, dengan peningkatan kuat tekan sebesar 21,83% ketika digunakan bersama *superplasticizer* 1% pada proporsi *fly ash* 24,1%. Untuk *superplasticizer*, proporsi optimal adalah 1%, dengan peningkatan kuat tekan sebesar 35,71% pada umur 14 hari. Sementara itu, proporsi optimal untuk *blast furnace slag* adalah 22,8%, dengan kuat tekan maksimum 43,29 MPa pada umur 28 hari.	Hasil dari penelitian ini menunjukkan bahwa model ANN mampu memprediksi dimensi dan biaya pekerjaan kolom dengan akurasi yang tinggi. Selain itu, nilai *error* antara biaya prediksi berdasarkan rumus empiris yang dihasilkan oleh ANN dengan biaya aktual adalah 1,78%, yang menunjukkan bahwa prediksi yang dihasilkan oleh model ANN sangat akurat. Model ANN juga berhasil memenuhi persyaratan struktur seperti *drift ratio*, *p-delta effect*, dan ketidakberaturan torsi, sehingga struktur hasil optimalisasi dapat dianggap aman dan efisien.	Model ANN pada *inter-ramp* 1 (atas) menunjukkan bahwa nilai prediksi SF optimal sebesar 1.25 berada pada kemiringan 46,06 derajat, *inter-ramp* 2 (tengah) menunjukkan bahwa nilai prediksi SF optimal sebesar 1.6638 berada pada kemiringan 50 derajat, dan *inter-ramp* 3 (bawah) menunjukkan bahwa nilai prediksi SF optimal sebesar 3.3820 berada pada kemiringan 50 derajat. Hasil prediksi dari model ANN kemudian dibandingkan dengan hasil analisis numerik yang telah dilakukan sebelumnya untuk menilai efektivitas dan akurasi model dalam melakukan optimalisasi nilai keamanan lereng (SF) yang nantinya akan menjadi pertimbangan untuk digunakan.

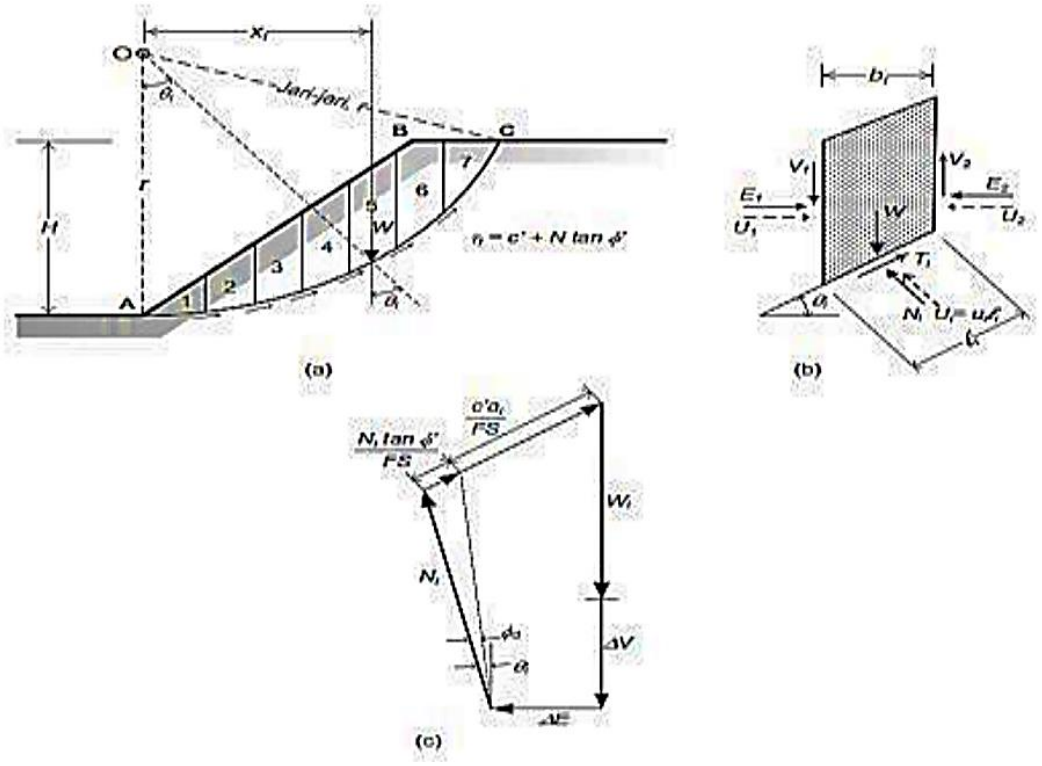
Penelitian ini memberikan perbedaan pada posisinya sebagai pengembangan lanjutan dalam pendekatan yang hangat dibicarakan saat ini yakni penggunaan model Artificial Neural Network (ANN) di bidang rekayasa geoteknik, terkhusus dalam optimalisasi nilai keamanan lereng (SF) di lokasi pertambangan. Berdasarkan tinjauan terhadap penelitian terdahulu, terlihat sebuah perkembangan dalam penerapan ANN, yang dimana Khan dkk. (2020) dan Hidayat dkk. (2022) berhasil membuktikan bahwa ANN dapat menangani hubungan non-linear pada data kestabilan lereng yang dibandingkan dengan metode konvensional. Hoading dkk. (2023) juga melalui analisisnya terhadap 159 studi yang menunjukkan bahwa berbagai metode salah satunya ANN mampu mencapai akurasi prediksi yang sangat tinggi ($R^2 > 0,9$). Sementara itu, penelitian lainnya seperti Gao dkk. (2019), Hibatulloh, M. (2024) dan Maji'Aturrohmah (2024) mengeksplorasi optimalisasi dalam bidang rekayasa sipil dimana objek dari penelitiannya adalah stabilitas tanah kohesif, campuran beton, dan juga struktur jembatan dengan menggunakan ANN untuk efisiensi biaya dan juga material.

Penelitian ini menawarkan integrasi metode analisis geoteknik dengan pemodelan ANN untuk tujuan optimalisasi nilai keamanan lereng (SF) dalam memprediksi sudut kemiringan lereng (α) yang aman berdasarkan banyaknya variasi model yang dibuat dengan parameter-parameter tanah dan lereng sebagai data *input* atau historis dalam pelatihan model. Penelitian ini juga menggunakan metode *Fellenius* melalui *software* GeoStudio (*Slope/W*) untuk menghasilkan nilai keamanan lereng (SF) beserta bidang gelincirnya. Model ANN dirancang dengan arsitektur yang meliputi 1 *input layer* yang terdiri dari 7 parameter himpunan data *input*, 3 *hidden layers* dengan 30, 20, dan 10 neuron dengan fungsi aktivasi ReLU, berserta 1 *output layer* untuk fungsi regresi, menggunakan bahasa pemrograman Python dengan *environment* Anaconda. Dengan demikian, penelitian ini tidak hanya memvalidasi kemampuan dari model ANN dalam membuat prediksi, akan tetapi juga digunakan sebagai model optimalisasi untuk menemukan nilai keamanan (SF) yang mendekati target atau syarat dengan menemukan sudut kemiringan lerengnya, yang berorientasi pada pendekatan praktis dalam konteks pertambangan.

BAB III
LANDASAN TEORI

3.1 Metode *Fellenius* (*Ordinary Method of Slice*)

Analisis stabilitas lereng dengan metode *Fellenius* (1936), beranggapan bahwa gaya memiliki sudut kemiringan paralel dengan dasar irisan faktor keamanan yang dihitung dengan kesetimbangan momen. Metode ini menganggap gaya-gaya yang bekerja pada sisi kanan-kiri dari sembarang irisan mempunyai resultan nol pada arah tegak lurus bidang longsor. Fellenius mengemukakan metodenya dengan menyatakan asumsi bahwa keruntuhan terjadi melalui rotasi dari suatu blok tanah pada permukaan longsor berbentuk lingkaran (sirkuler) dengan titik O sebagai titik pusat rotasi, sehingga gaya normal P bekerja di tengah-tengah *slice*.



Gambar 3.1 Lereng Dengan Busur Lingkaran Bidang Longsor
(Sumber: Das, Bradja M., 1994)

Pada Gambar 3.1 suatu lereng dengan sistem irisan untuk berat sendiri massa tanah (W) serta analisis komponen gaya-gaya yang timbul dari berat massa tanah tersebut, yang terdiri dari gaya-gaya antar irisan yang bekerja di samping kanan irisan (Et dan Vt). Pada bagian alas irisan, gaya berat (W) diuraikan menjadi gaya reaksi normal U_1 yang bekerja tegak lurus alas irisan dan gaya tangensial T_1 yang bekerja sejajar irisan. Besarnya gaya lengan gaya (W) adalah x = r sin θ, dimana r adalah jari-jari lingkaran longsor dan sudut θ adalah sudut pada titik O yang dibentuk antara garis vertikal dengan jari-jari lingkaran longsor.

Dengan menggunakan prinsip dasar serta asumsi-asumsi di atas, maka nilai keamanan dapat didefinisikan dengan Persamaan 3.1 dan 3.2 sebagai berikut.

$$SF = \frac{\sum M_R}{\sum M_D} \tag{3.1}$$

$$SF = \frac{\text{Jumlah momen dari tahanan geser yang menahan longsor}}{\text{Jumlah momen yang menggerakkan longsor}} \tag{3.2}$$

Sehingga, persamaan untuk nilai keamanan dapat menjadi Persamaan 3.3 sebagai berikut.

$$SF = \frac{\sum_{i=1}^{i=n} c a_i + (W_i \cos \theta_i - u_i a_i) \operatorname{tg} \varphi}{\sum_{i=1}^{i=n} W_i \sin \theta_i + q} \tag{3.3}$$

dengan:

SF = Faktor keamanan,

n = Jumlah irisan,

c = Kohesi tanah efektif (kN/m^2),

a_i = Panjang lengkung lingkaran pada irisan ke-i (m),

W_i = Berat massa tanah irisan ke-i (kN/m^3),

θ_i = Sudut kemiringan lereng yang didefinisikan (°),

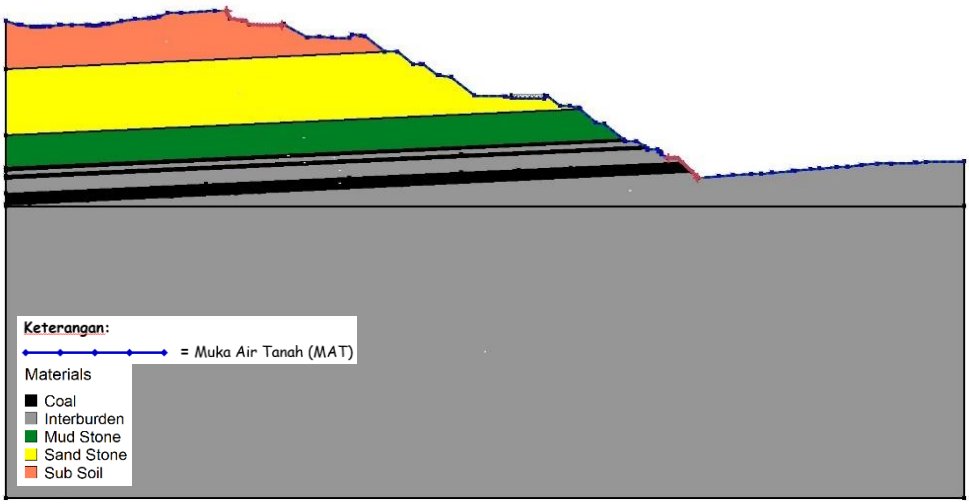
u_i = Tekanan air pori (kN/m^2),

φ = Sudut geser dalam tanah (°), dan

q = Beban merata (kN/m^2).

3.2 *Slope/W*

Slope/W adalah perangkat lunak analisis stabilitas lereng yang dikembangkan oleh *Geo-Slope International*. Metode ini digunakan untuk mengevaluasi stabilitas lereng dengan mempertimbangkan berbagai faktor yang mempengaruhi kestabilan, seperti geometri lereng, sifat material, dan kondisi air. Metode pencariannya dilakukan dengan menggunakan *entry and exit* yang mensimulasikan ribuan kemungkinan busur lingkaran bidang gelincir. *Slope/W* menggunakan metode analisis keseimbangan batas (*limit equilibrium*) dalam menentukan nilai keamanan lereng (SF). Contoh dari pemodelan lereng menggunakan analisis *Slope/W* dengan pendekatan keseimbangan batas (*limit equilibrium*) dapat dilihat seperti pada Gambar 3.2 sebagai berikut.



Gambar 3.2 Contoh Pemodelan Lereng dengan *Slope/W*

Analisis keseimbangan batas (*limit equilibrium*) berfokus pada keseimbangan gaya yang bekerja pada massa tanah. Dalam analisis ini, gaya geser, gaya normal, dan gaya luar (seperti beban tambahan) diperhitungkan untuk menentukan apakah lereng dalam keadaan stabil atau tidak dengan mempertimbangkan nilai keamanan lereng (SF) yaitu rasio di antara gaya yang menahan lereng dari yang bergerak (gaya geser) dalam hal ini adalah M_R (*Moment Resisting)* dan gaya yang mendorong lereng untuk bergerak (gaya gravitasi) dalam hal ini adalah M_D (*Moment Driving*). SF > 1.25 menunjukkan stabilitas, sedangkan SF < 1.25 menunjukkan

ketidakstabilan. Adapun komponen utama dalam *Slope/W* ini yaitu geometri lereng, sifat material, kondisi air, dan beban eksternal struktur di atas lereng.

3.3 *Artificial Neural Network* (ANN)

Artificial Neural Network (ANN) adalah jaringan saraf tiruan yang merupakan model matematis yang dibentuk dengan prinsip yang sama dengan cara kerja sistem saraf biologis atau otak manusia, yakni dengan cara memproses informasi secara paralel melalui banyak unit pemrosesan yang dikenal sebagai neuron, sehingga memungkinkan ANN untuk memodelkan dan menyelesaikan masalah yang kompleks (Sari dkk., 2024). *Artificial Neural Network* sederhana pertama kali diperkenalkan oleh McCulloch dan Pitts pada tahun 1943 dan terus berkembang hingga kemajuan signifikan terjadi pada tahun 1990. Pada waktu itu, perhatian besar diberikan pada penerapan model-model *Artificial Neural Network* untuk menyelesaikan berbagai masalah di dunia nyata (Rada dan Aji, 2019). ANN telah banyak digunakan dalam berbagai bidang, termasuk kecerdasan buatan, ilmu komputer, teknik sipil, dan lain-lain. Mengacu pada (Siang, 2009), *Artificial Neural Network* dapat diaplikasikan pada hal berikut:

1. Pengenalan Pola (*Pattern Recognition*)

   Artificial Neural Network dapat digunakan untuk mengenali pola seperti huruf, angka, suara, dan tanda tangan yang telah mengalami sedikit perubahan. Kemampuan ini mirip dengan otak manusia, yang tetap dapat mengenali seseorang meskipun penampilannya telah sedikit berubah setelah beberapa waktu tidak bertemu.

2. Pemrosesan Sinyal (*Signal Processing*)

   Model ADALINE dari *Artificial Neural Network* dapat digunakan untuk mengurangi *noise* atau gangguan dalam saluran telepon, membantu meningkatkan kualitas sinyal.

3. Prediksi (*Prediction*)

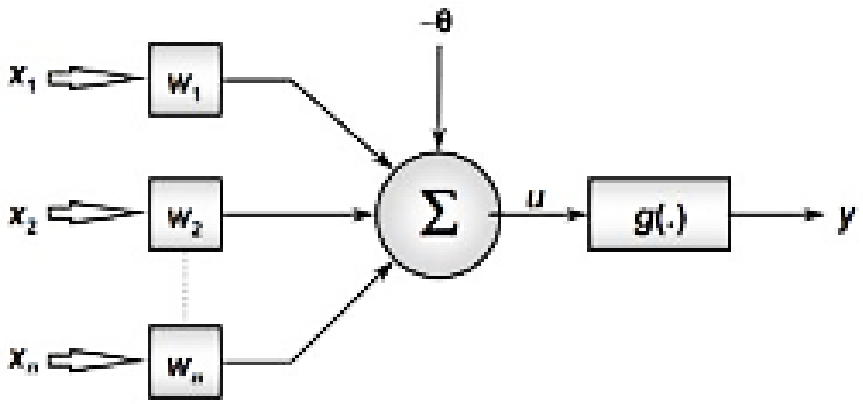
   Artificial Neural Network dapat digunakan untuk memprediksi kejadian di masa depan berdasarkan pola dari data masa lalu. Hal ini dimungkinkan

karena jaringan saraf tiruan memiliki kemampuan untuk mengingat dan membuat generalisasi dari data yang telah dipelajarinya sebelumnya.

Meskipun ANN memiliki keunggulan dalam pemodelan dan analisis data, terdapat beberapa kelemahan, seperti kesulitan dalam menginterpretasikan hasil serta kebutuhan akan jumlah data yang besar untuk melatih model. Selain itu, karakterisitik ANN juga sangat dipengaruhi oleh pola hubungan antar-neuron (dikenal sebagai arsitektur jaringan), metode penentuan bobot sambungan (dikenal pelatihan atau proses belajar jaringan), dan fungsi aktivasi yang mengatur respons dari neuron-neuron tersebut.

3.3.1 *Artificial Neuron*

Struktur *Artificial Neural Network* dikembangkan dengan mengacu pada model-model sistem saraf biologis dan otak manusia. *Artificial Neuron* atau jaringan tiruan merupakan unit pemrosesan komputasional yang disederhanakan dari model neuron biologis. Neuron tiruan dalam jaringan saraf tiruan bersifat non-linier. Neuron ini biasanya menghasilkan *output* yang kontinu dan melakukan tugas-tugas sederhana. Tugas-tugas tersebut meliputi mengumpulkan sinyal dari *input* yang tersedia, mengolahnya sesuai dengan fungsi operasional, dan menghasilkan respons berdasarkan fungsi aktivasi yang telah ditentukan (Sari dkk., 2024). Ilustrasi pemodelan *Artificial Neuron* dapat dilihat pada Gambar 3.3 sebagai berikut.



Gambar 3.3 Model *Artificial Neuron*
(Sumber: Sari dkk., 2024)

Setiap neuron dalam jaringan saraf tiruan (ANN) dapat digambarkan seperti pada Gambar 3.3. Sinyal *input* dari luar sistem (neuron *input*), disebut sebagai himpunan {x1, x2, x3, ..., xn}, yang mirip dengan sinyal listrik yang diterima oleh dendrit di neuron biologis. Setiap sinyal *input* ini dikalikan dengan bobot sinapsis yang sesuai {w1, w2, ..., wn}, yang mewakili relevansi atau kepentingan masing-masing sinyal. Setelah itu, semua sinyal yang sudah ditimbang ini kemudian dijumlahkan menjadi agregator linear, seperti yang ditunjukkan oleh simbol $\sum$ pada gambar. Hasil dari penjumlahan ini, yang disebut sebagai u, kemudian dikurangi dengan nilai ambang batas (θ) yang menjadi target atau syarat yang digunakan. Nilai u ini kemudian diproses melalui fungsi aktivasi pengkodingan ANN yang disebut sebagai g(.) untuk menghasilkan *output* akhir berupa y. Proses ini menggambarkan bagaimana neuron tiruan mengambil informasi dari berbagai sumber, memberikan bobot pada informasi tersebut, dan kemudian menentukan *output* berdasarkan informasi yang telah diproses.

Neuron tiruan memiliki tujuh elemen dasar seperti yang tergambar pada Gambar 3.3, dengan penjabaran masing-masing elemen sebagai berikut:

1. Neuron *Input* atau Sinyal Masukan (x_i)

   Sinyal masukan merupakan atau sampel yang berasal dari lingkungan eksternal dan mewakili nilai-nilai yang diasumsikan oleh variabel-variabel dalam suatu aplikasi tertentu. Sinyal masukan ini biasanya dinormalisasi untuk meningkatkan efisiensi komputasi dari algoritma pembelajaran. Normalisasi ini membantu memastikan bahwa proses pembelajaran berlangsung lebih cepat dan stabil, dengan mengurangi risiko masalah seperti *gradient vanishing* atau *exploding* pada jaringan saraf tiruan.

2. Bobot Sinapsis (w_i)

   Bobot sinapsis adalah nilai yang digunakan untuk memberikan bobot pada setiap variabel masukan, sehingga memungkinkan pengukuran seberapa relevan setiap *input* terhadap fungsi neuron. Bobot ini menentukan seberapa besar pengaruh suatu sinyal masukan terhadap *output* akhir yang dihasilkan oleh neuron tiruan.

3. Agregator Linear ($\sum$)

Agregator linear menghimpun semua sinyal masukan yang telah diberi bobot oleh sinapsis untuk menghasilkan tegangan aktivasi. Tegangan aktivasi ini merupakan hasil penjumlahan dari sinyal-sinyal tersebut setelah dikalikan dengan bobot masing-masing, dan digunakan sebagai *input* untuk fungsi aktivasi yang menentukan *output* akhir neuron tiruan.

4. Ambang Aktivasi atau Bias (θ)

   Ambang aktivasi atau bias adalah nilai yang digunakan untuk menentukan batasan agar hasil dari agregator linier dapat memicu neuron untuk menghasilkan *output*. Bias membantu mengatur kapan neuron akan aktif atau terpicu untuk menghasilkan hasil tertentu.

5. Potensi Aktivasi (u)

   Potensi aktivasi adalah hasil dari selisih antara agregator linier dan ambang aktivasi. Jika nilai ini positif, yaitu jika agregator linier lebih besar dari atau sama dengan ambang aktivasi ($u \geq \theta$), maka neuron menghasilkan potensi eksitatori. Sebaliknya, jika nilai ini negatif, yaitu jika agregator linier kurang dari ambang aktivasi ($u < \theta$), maka potensi bersifat inhibitori.

6. Fungsi Aktivasi (g(.))

   Fungsi aktivasi digunakan untuk membatasi *output* neuron sehingga berada dalam rentang nilai yang wajar. Fungsi ini menentukan batasan pada hasil keluaran neuron sesuai dengan bentuk fungsinya.

7. *Output* Neuron atau Sinyal Keluaran (y)

   Sinyal keluaran adalah nilai akhir yang dihasilkan oleh neuron berdasarkan sinyal masukan yang diterimanya. Nilai ini juga bisa digunakan sebagai masukan untuk neuron lain yang terhubung secara berurutan.

Untuk menjelaskan lebih lanjut, proses yang dijabarkan sebelumnya dapat dimodelkan dengan Persamaan 3.4 dan Persamaan 3.5 sebagai berikut.

$$u = \sum_{i=1}^{i=n} (x_i - w_i) - \theta \tag{3.4}$$

$$y = g(.)\,(u) \tag{3.5}$$

dengan:

x_i = Sinyal *input* ke-i,

w_i = Bobot sinapsis yang terkait dengan *input* ke-i,

θ = Nilai ambang batas,

u = Potensi aktivasi,

g (.) = Fungsi aktivasi, dan

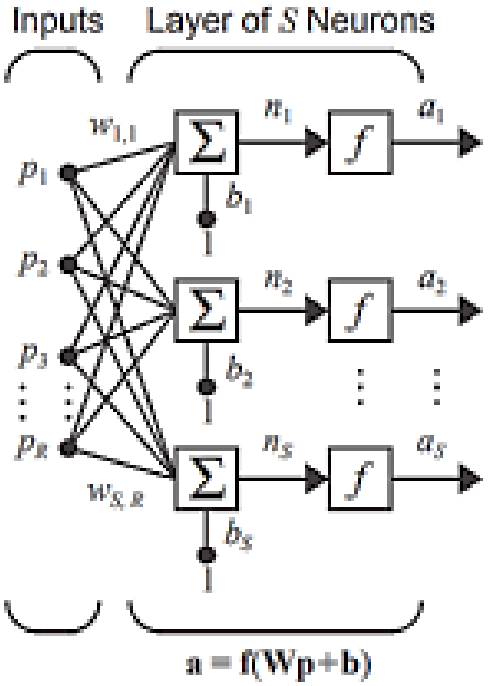
y = Sinyal *output* yang dihasilkan.

3.3.2 Artisektur Jaringan *Artificial Neural Network*

Arsitektur jaringan yang umumnya digunakan dalam pemodelan yaitu:

1. Jaringan Saraf Lapis Tunggal (*Single Layer Networks*)

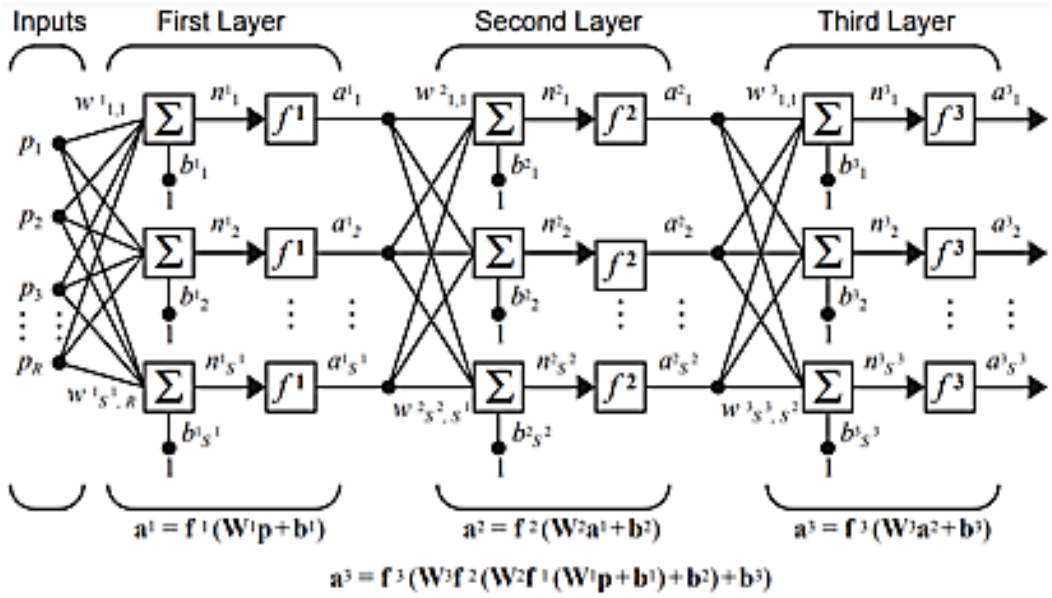
   Jaringan dengan layer tunggal hanya memiliki satu lapisan *input* dan satu lapisan *output*. Jaringan ini hanya menerima *input* dan kemudian mengolahnya menjadi *output* tanpa perlu melalui lapisan tersembunyi (*hidden layer*). Model arsitektur jaringan saraf lapis tunggal ditunjukkan pada Gambar 3.4 sebagai berikut.



Gambar 3.4 Arsitektur Jaringan Saraf Lapis Tunggal
(Sumber: Neural Network Design, 2002)

2. Jaringan Saraf Lapis Jamak (*Multilayer Network*)

Jaringan dengan lapisan jamak (*multi layer*) memiliki ciri khas tertentu, yaitu terdiri dari tiga jenis lapisan: lapisan *input* (*input layer*), lapisan *output* (*output layer*), dan lapisan tersembunyi (*hidden layer*). *Input layer* digunakan untuk menerima nilai masukan dari setiap rekaman dalam data, dengan jumlah simpul yang sesuai dengan jumlah variabel prediktor. *Hidden layer* bertugas untuk mentransformasikan nilai *input* di dalam jaringan. Setiap simpul pada *hidden layer* terhubung dengan simpul-simpul pada *input layer* dan simpul-simpul pada *hidden layer* berikutnya atau pada *output layer*. Jumlah *hidden layer* dapat bervariasi sesuai kebutuhan (Vercellis, 2009). *Hidden layer* dapat terdiri dari satu atau lebih lapisan yang terletak di antara *input layer* dan *output layer*. Jaringan dengan lapisan jamak ini mampu menyelesaikan masalah yang lebih kompleks dibandingkan dengan jaringan dengan lapisan tunggal, meskipun proses pelatihannya terkadang lebih rumit dan memakan waktu lebih lama (Arif, 2006). Model arsitektur jaringan saraf lapis jamak ditunjukkan pada Gambar 3.5 sebagai berikut.



Gambar 3.5 Arsitektur Jaringan Saraf Lapis Jamak
(Sumber: Neural Neutwork Design, 2002)

3.3.3 *Hyperparameter Neural Network*

Hyperparameter pada *Neural Network* adalah parameter yang tidak dipelajari secara langsung selama proses pelatihan model, melainkan harus diatur sebelumnya oleh pengguna. Optimisasi *hyperparameter* adalah bagian mendasar dari *Machine Learning* (ML) dan telah banyak diteliti dalam beberapa tahun terakhir. Namun, ini masih menjadi salah satu tantangan utama di bidang ini (Japa dkk., 2023). Pemilihan *hyperparameter* yang tepat sangat penting karena mereka memengaruhi kinerja dan kemampuan generalisasi model. Namun, karena tidak ada metode baku untuk menentukan nilai *hyperparameter* terbaik, proses ini sering kali memerlukan eksperimen yang berulang kali, yang bisa memakan waktu dan sumber daya. Untuk metode optimalisasi, digunakan fungsi *grid search*. Menurut Japa dkk. (2023), *Grid Search* melakukan pencarian dengan mempertimbangkan *grid* multi-dimensi dari kombinasi *hyperparameter*. Rentang untuk setiap *hyperparameter* dalam *grid* biasanya ditentukan oleh pengguna. *Grid Search* kemudian menghitung produk Kartesius dari kombinasi *hyperparameter* yang memungkinkan. Karena beberapa *hyperparameter* dapat memiliki nilai yang tak terbatas, pengguna juga harus mendefinisikan langkah untuk melompat dari satu nilai *hyperparameter* ke nilai berikutnya. Ketika dilakukan oleh spesialis, nilai-nilai yang diambil dari *grid* ini dapat menghasilkan model pembelajaran yang memuaskan.

Optimisasi *hyperparameter* dalam *Neural Network* melibatkan beberapa komponen penting, di antaranya:

1. Jumlah Lapis dan Neuron pada *Hidden Layer*

   Hubungan antar neuron dalam *Artificial Neural Network* (ANN) mengikuti pola tertentu yang sesuai dengan arsitekturnya dan terkait dengan algoritma pembelajaran yang digunakan untuk melatih jaringan tersebut. Pemodelan ANN menggunakan algoritma untuk membentuk jaringan yang mampu mempelajari informasi atau data yang diberikan. Biasanya, satu neuron dengan banyak *input* mungkin tidak cukup, sehingga diperlukan beberapa neuron yang bekerja secara paralel dalam suatu lapisan (*layer*). Untuk menyederhanakan algoritma, dibentuklah model arsitektur jaringan dengan mengumpulkan data *input* hingga membentuk lapisan-lapisan (*layer*) yang

jumlahnya disesuaikan dengan data yang ada. Konsep lapisan ini penting dalam membangun arsitektur ANN yang efektif.

2. Fungsi Aktivasi

Fungsi aktivasi digunakan untuk membatasi *output* neuron sehingga berada dalam rentang nilai yang wajar. Fungsi aktivasi ditetapkan agar model dapat menyesuaikan secara spesifik dengan masalah yang akan dimodelkan menggunakan jaringan saraf tiruan. Dengan demikian, algoritma yang sesuai untuk masalah tersebut dapat diidentifikasi oleh program yang dibangun. Ada beberapa jenis fungsi aktivasi yang digunakan dalam pemodelan *Neural Network*, seperti yang ditunjukkan pada Tabel 3.1 sebagai berikut.

Tabel 3.1 Jenis Fungsi Aktivasi

Nama	**Hubungan *Input/Output***	**Ikon**	**Fungsi**
Hard Limit	$a = 0 \quad n < 0$ $a = 1 \quad n \geq 0$		hardlim
Symmetrical Hard Limit	$a = -1 \quad n < 0$ $a = +1 \quad n \geq 0$		hardlims
Linear	$a = n$		purelin
Saturating Linear	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n \leq 1$ $a = 1 \quad n > 1$		satlin
Symmetric Saturating Linear	$a = -1 \quad n < -1$ $a = n \quad -1 \leq n \leq 1$ $a = 1 \quad n > 1$		satlins
Log-Sigmoid	$a = \frac{1}{1 + e^{-n}}$		logsig
Hyperbolic Tangent Sigmoid	$a = \frac{e^{n} - e^{-n}}{e^{n} + e^{-n}}$		tansig
Positive Linear	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n$		polsin
Competitive	$a = 1$ neuron dengan n maks $a = 0$ semua neuron lain		compet

(Sumber: Neural Network Desgin, 2002)

3. Ukuran Batch (*Batch Size*) dan *Epoch*

   Kusuma (2022) menyatakan bahwa *batch size* adalah parameter yang menentukan jumlah sampel yang digunakan dalam proses pelatihan. Pengaturan *batch size* mempengaruhi durasi pelatihan dan potensi terjadinya *overfitting*. Dalam kondisi tertentu, ukuran *batch size* juga berdampak pada efisiensi komputasi. Semakin besar *batch size*, semakin cepat waktu yang diperlukan untuk menyelesaikan proses pelatihan. Sedangkan *epoch* adalah kondisi di mana seluruh *dataset* telah melewati proses pelatihan dalam jaringan neural sebanyak satu kali. Jumlah *epoch* mempengaruhi proses pembelajaran, namun jumlah yang optimal bervariasi tergantung pada kasus yang dihadapi. Semakin tinggi jumlah *epoch*, semakin banyak waktu yang dibutuhkan untuk mempelajari *dataset* secara keseluruhan.

4. *Optimizer* dan Laju Pembelajaran (*Learning Rate*)

   Optimizer berfungsi untuk memperbarui bobot dan bias berdasarkan informasi kesalahan dari hasil prediksi. Tujuan utamanya adalah meminimalkan kesalahan (melakukan optimisasi terhadap fungsi *loss*) sebanyak mungkin, dimana pengaturan *learning rate* yang akan menentukan seberapa cepat dan mendetail model dalam belajar. Semakin kecil *learning rate*, semakin lama waktu yang dibutuhkan model untuk mencapai konvergensi (dengan biaya komputasi yang tinggi), namun proses belajarnya menjadi lebih detail dan akurat. Dalam konteks ini, Kingma dan Ba (2015) menyatakan bahwa *stochastic gradient-based optimization* menjadi metode yang sangat penting dalam berbagai bidang ilmu dan teknik. Metode ini memungkinkan optimasi fungsi objektif skalar yang membutuhkan maksimisasi atau minimisasi terhadap parameternya. Jika fungsi objektif tersebut dapat dibedakan terhadap parameternya, *gradient descent* menjadi metode yang efisien karena perhitungan turunan parsial terhadap semua parameter memiliki kompleksitas komputasi yang sama dengan evaluasi fungsi itu sendiri.

   Dalam penelitian ini akan digunakan Adam (*Adaptive Moment Estimation*) sebagai metode optimasi stokastik untuk meminimalkan fungsi kerugian (*loss*

function) dan meningkatkan kinerja model dalam memprediksi atau mengklasifikasikan data selama pelatihan model atau jaringan saraf dengan pembelajaran mendalam karena efisiensi dan adaptabilitasnya yang menggabungkan algoritma optimasi Momentum dan RMSprop yang memiliki *learning rate* dalam mengoptimasi sebesar 0,001. Adam hanya memerlukan gradien orde pertama dengan kebutuhan memori yang minimal. Metode ini menghitung laju pembelajaran adaptif secara individual untuk berbagai parameter berdasarkan estimasi momen pertama dan kedua dari gradien. Salah satu keuntungan dari Adam adalah bahwa magnitudo pembaruan parameter tidak terpengaruh oleh skala ulang gradien, dan metode ini dapat bekerja dengan baik meskipun dalam kondisi yang tidak stasioner dan pada gradien yang jarang (Kingma dan Ba, 2015).

3.3.4 Pelatihan *Artificial Neural Network*

Terdapat dua jenis pelatihan jaringan berdasarkan cara memodifikasi bobotnya, yaitu pelatihan dengan supervisi (*supervised learning*) dan pelatihan tanpa supervisi (*unsupervised learning*) (Rada dan Aji, 2019). Penjelasan mengenai masing-masing jenis pelatihan sebagai berikut.

1. *Supervised Learning*

   Dalam pelatihan dengan supervisi, digunakan sejumlah pasangan data (*input-output*) untuk melatih jaringan hingga bobot yang diinginkan tercapai. Pasangan data ini berfungsi sebagai “pembimbing” yang membimbing jaringan untuk mencapai bentuk terbaik. “Pembimbing” memberikan informasi yang jelas mengenai bagaimana sistem harus mengubah dirinya untuk meningkatkan kinerja. Salah satu jaringan saraf lapis jamak yang termasuk kedalam jenis *supervised learning* adalah jaringan perambatan balik (*backpropagation*).

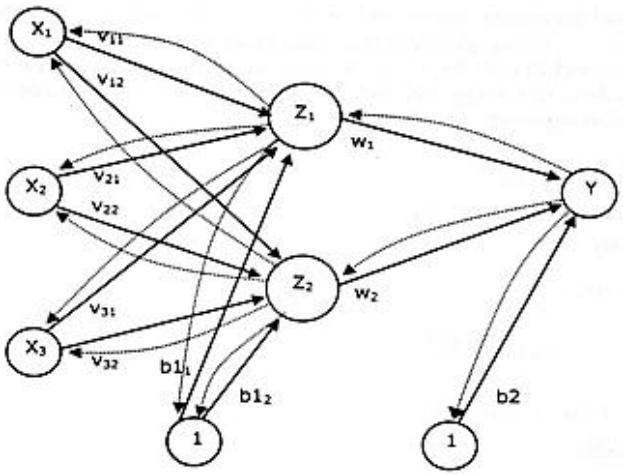
2. *Unupervised Learning*

   Dalam pelatihan tanpa supervisi, tidak ada "pembimbing" yang mengarahkan proses pelatihan. Sebaliknya, perubahan bobot jaringan dilakukan berdasarkan parameter tertentu, dan jaringan dimodifikasi sesuai dengan

ukuran parameter tersebut. Adapun dalam penelitian ini, jenis *Artificial Neural Network* yang digunakan termasuk ke dalam jenis *supervised learning*, yang berarti ANN bekerja dengan cara melakukan iterasi berulang-ulang untuk meminimalkan kesalahan (*error*) dalam memprediksi *output* berdasarkan data *input* yang ada. ANN belajar dengan menggunakan pasangan *input-output* yang telah diketahui untuk memodifikasi bobotnya agar menghasilkan prediksi yang lebih akurat.

3.3.5 *Algoritma Backpropogation*

Algoritma backpropagation (BP) adalah algoritma yang sering digunakan untuk menyelesaikan masalah-masalah kompleks. *Algoritma backpropagation* ini pertama kali dirumuskan oleh Werbos dan kemudian dipopulerkan oleh Rumelhart dan McClelland untuk digunakan dalam jaringan saraf tiruan (Rada dan Aji, 2019). Konsep kerja algoritma ini mirip dengan konsep beberapa model arsitektur yang telah dipaparkan sebelumnya. Dalam algoritma ini, pembobot (w) pada neuron diperbarui secara mundur (*backward*) berdasarkan *error output* yang dihasilkan dari fungsi aktivasi. Untuk memperoleh *error output* tersebut, fungsi dijalankan terlebih dahulu secara maju (*forward*) dan kemudian diproses mundur (*backpropagate*) dengan bias (b) pada fungsi tersebut. Model jaringan arsitektur dari algoritma *backpropagation* dapat dilihat pada Gambar 3.5 sebagai berikut.



Gambar 3.6 Arsitektur Jaringan Saraf Lapis Jamak
(Sumber: Alfis, 2013)

Secara umum, proses algoritma *back propagation* terdiri dari langkah-langkah berikut (Adhi, 2009):

1. Melakukan penetapan awal bobot dan bias,
2. Menyebarkan nilai pada setiap unit *input* ke seluruh jaringan di *hidden layer*,
3. Menghitung nilai *input* dari *hidden layer*,
4. Menghitung nilai *output* dari *hidden layer*,
5. Menyebarkan nilai setiap *input* pada unit di *hidden layer* ke seluruh jaringan di *output layer*,
6. Menghitung koreksi *error* pada unit di *output layer*,
7. Menghitung koreksi *error* pada unit di *hidden layer*,
8. Memperbarui bobot dan bias pada *output layer*,
9. Memperbarui bobot dan bias pada *hidden layer*, dan
10. Mengulangi langkah 2 hingga langkah 9 untuk perbaikan bias dan bobot.

3.3.6 Pemodelan *Artificial Neural Network*

Pemodelan algoritma dimulai dengan cara melatih *dataset* yang dimiliki. Konfigurasi pemodelan ini terdiri dari tiga lapisan: *input layer*, *hidden layer*, dan *output layer*. *Input layer* berisi kumpulan data yang berfungsi untuk memproses informasi guna menghasilkan *output*. *Hidden layer* adalah lapisan yang memproses dan mentransformasi data antara *input* dan *output layer*, menangkap pola kompleks dalam data. *Output layer*, di sisi lain, merupakan hasil akhir berupa persamaan numerik yang berasal dari pemrosesan data *input*. Rencana penerapan ANN dalam penelitian ini adalah sebagai berikut.

1. Pemodelan ANN untuk optimalisasi nilai keamanan lereng (SF).

   Input :

   a. Data tanah yang terdiri dari:
      1) Nilai kohesi tanah (c);
      2) Sudut geser dalam (φ);
      3) Berat volume tanah (γ).
   b. Topografi lereng yang terdiri dari:
      1) Ketinggian lereng (H);

2) Sudut kemiringan lereng (α).

c. Stratigrafi lereng (lapisan lereng),

d. Muka air tanah (MAT), dan

e. Beban merata (q).

Output : Nilai keamanan lereng (SF)

2. Dalam penelitian ini, akan dilakukan *trial and eror* menggunakan *Multiple-Layer Network* (MLP) yang memungkinkan penggunaan fungsi transfer yang berbeda (baik linear maupun non-linear) serta memiliki risiko *error* yang lebih kecil.

3. Parameter *input* dan *output* yang telah didefinisikan pada poin 1 perlu dinormalisasikan untuk mempersiapkan data sebelum analisis. Metode *MinMax Scaling* mengubah data ke dalam rentang 0 hingga +1, sehingga mengurangi risiko terjadinya *error* yang besar. Di sisi lain, metode *standard scaler* mengubah data dengan cara mengurangi rata-rata dan membagi dengan deviasi standar, sehingga menghasilkan distribusi dengan rata-rata 0 dan deviasi standar 1. Dalam penelitian ini, akan dilakukan percobaan untuk menguji kedua metode ini dan menentukan mana yang lebih efektif untuk analisis data.

4. Setelah data dinormalisasi, langkah selanjutnya adalah memasukkan semua data ke dalam program dan menentukan jumlah lapis dan neuron/*node* pada *hidden layer* yang sesuai. Tidak ada metode langsung untuk memilih jumlah lapis dan neuron/*node*, sehingga umumnya digunakan metode *trial-error*. Beberapa percobaan diperlukan untuk menentukan jumlah *hidden layer* yang menghasilkan hasil terbaik. Menurut Fausset L. (1994), satu *hidden layer* sudah cukup untuk *backpropagation network* dalam memprediksi pemetaan berkelanjutan dari pola *input* ke *output*. Namun, dalam kondisi tertentu, dua atau lebih *hidden layer* dapat mempermudah proses percobaan.

5. Selain jumlah lapis dan jumlah neuron, diperlukan juga untuk menentukan *hyperparameter* lain seperti fungsi aktivasi, jenis optimizer, jumlah epoch serta ukuran *batch* yang akan diujikan pada model.

6. Setelah menentukan beberapa *hyperparameter* melalui metode *trial-error*, langkah selanjutnya adalah menjalankan program untuk memperoleh model yang bisa digunakan untuk optimalisasi nilai keamanan lereng (SF).
7. Optimalisasi nilai keamanan lereng (SF) dilakukan dengan memanfaatkan model ANN yang telah dibangun. Proses ini melibatkan penerapan model ANN pada variabel desain yakni model-model yang telah divariasi dengan sudut kemiringan lereng (α) berdasarkan data-data tanah dan geometri lereng yang telah dimasukkan dan dianalisis. Model ANN digunakan untuk memprediksi nilai keamanan lereng (SF) yang optimal dari berbagai skema atau variasi lereng yang dibuat. Model kemudian dilatih dan diuji yang selanjutnya akan menghasilkan nilai keamanan lereng (SF) yang optimal dari variasi sudut kemiringannya. Hasil prediksi model tersebut kemudian di evaluasi dengan menghitung nilai *error* dari kinerja model atau memberikan gambaran seberapa akurat model dalam membuat prediksi dengan *loss function*. Model terbaik yang memberikan sudut kemiringan (α) dengan nilai keamanan (SF) paling optimal sesuai dengan target atau syarat yang digunakan sebesar 1.25 akan dipilih sebagai hasil optimalisasi untuk dijadikan pertimbangan atau rekomendasi.

3.3.7 *Loss Function*

Setelah model ANN dilatih dan diuji dengan *dataset* yang ada, langkah selanjutnya adalah menghitung nilai *error* untuk mengevaluasi kinerja model. Dalam pengolahan data yang bersifat estimasi dan masih mengandung unsur ketidakpastian, penting untuk memasukkan nilai *error* sebagai pengukuran akurasi dari estimasi tersebut (Sembiring, 2024). Untuk setiap nilai, diperlukan perhitungan nilai *error* untuk membandingkan hasil *input* dengan target *output* (Rada dan Aji, 2019). *Loss Function* atau perhitungan *error* yang digunakan pada pengujian kali ini adalah *Root Mean Square Error* (RMSE), koefisien determinasi (R^2), dan *Mean Absolute Percentage Error* (MAPE) dengan rincian sebagai berikut.

1. *Root Mean Square Error* (RMSE)

   Root Mean Square Error adalah metode pengukuran yang digunakan untuk mengukur perbedaan antara nilai prediksi model dan nilai yang diobservasi. RMSE merupakan hasil akar kuadrat dari *Mean Square Error* (MSE). Semakin kecil nilai RMSE yang diperoleh, semakin akurat metode yang digunakan (Ridlo dkk., 2023). Adapun perhitungan RMSE ditunjukkan pada Persamaan 3.6 sebagai berikut.

$$\text{RMSE} = \sqrt{\frac{\sum(\text{At} - \text{Ft})^2}{\text{n}}} \tag{3.6}$$

   dengan:

   A_t = Target *output* atau nilai aktual data,

   F_t = *Output* jaringan atau nilai hasil prediksi, dan

   n = Jumlah data.

   Keterangan:

   RMSE $\leq$ 0,1 = Sangat baik

2. Koefisien Determinasi (R^2)

   Koefisien determinasi digunakan untuk mengukur kemampuan model untuk menjelaskan variabel dependen yang berbeda dan memiliki kekuatan penjelas yang tinggi atau hubungan linier dalam data (Moore dkk., 2013). Nilai koefisien determinasi berkisar dari nol hingga satu, dimana jika nilai R^2 mendekati nol menunjukkan bahwa model tidak banyak menjelaskan variabilitas variabel dependen. Variabel independen dalam model mungkin tidak memiliki kekuatan penjelas yang signifikan terhadap variabel dependen. Sebaliknya, jika R^2 mendekati satu, ini menunjukkan bahwa model menjelaskan sebagian besar variabilitas variabel dependen. Dengan kata lain, model memiliki kekuatan penjelas yang tinggi. Koefisien determinasi merupakan salah satu metrik untuk mengevaluasi model, tetapi tidak selalu memberikan gambaran lengkap tentang kualitas model. Misalnya, nilai R^2 yang tinggi tidak selalu berarti model adalah model terbaik, karena model

yang terlalu kompleks dapat memiliki R^2 tinggi tetapi performa yang buruk pada data yang tidak terlihat (*overfitting*).

Nilai R^2 di bawah 0,3 menunjukkan hubungan linier yang sangat lemah. Rentang 0,3 hingga 0,5 menunjukkan hubungan linier yang rendah, sedangkan nilai antara 0,5 dan 0,9 menunjukkan hubungan linier yang sedang. Nilai R^2 di atas 0,9 menunjukkan hubungan linier yang kuat (Moore dkk., 2013).

Perhitungan nilai R^2 dapat dihitung menggunakan rumus pada Persamaan 3.7 sebagai berikut.

$$R^2 = 1 - \frac{\sum(At - Ft)^2}{\sum(At - Ft)^2} \quad (3.7)$$

dengan:

R^2 = Koefisien determinasi,

A_t = Target *output* atau nilai aktual data, dan

F_t = *Output* jaringan atau nilai hasil prediksi.

Keterangan:

$R^2 < 30\%$ = Sangat lemah

$30\% \leq R^2 < 50\%$ = Lemah

$50\% \leq R^2 < 90\%$ = Sedang

$90\% \leq R^2 \leq 100\%$ = Kuat

3. *Mean Absolute Percentage Error* (MAPE)

Mean Absolute Percentage Error merupakan persentase kesalahan rata-rata absolut yang sering digunakan dalam statistik untuk mengukur akurasi. MAPE dihitung dengan mengambil rata-rata persentase selisih absolut antara data asli dan data prediksi (Ridlo dkk., 2023).

Nilai MAPE dapat dihitung menggunakan rumus pada Persamaan 3.8 sebagai berikut.

$$MAPE = \frac{1}{n} \sum \left| \frac{A - Ft}{At} \right| \times 100\% \quad (3.8)$$

dengan:

A_t = Target *output* atau nilai aktual data,

F_t = *Output* jaringan atau nilai hasil prediksi, dan

n = Jumlah data.

Keterangan:

MAPE $<$ 10% = Sangat akurat

10% $\leq$ MAPE $<$ 20% = Baik

20% $\leq$ MAPE $\leq$ 50% = Layak

MAPE $>$ 50% = Kurang akurat

Hasil interpretasi nilai MAPE menunjukkan beberapa kategori tingkat akurasi peramalan. Lewis (1982) dan Afifuddin dkk. (2021) menyatakan bahwa nilai MAPE yang kurang dari 10% menandakan peramalan yang sangat akurat. Jika nilai MAPE berada di antara 10% hingga 20%, peramalan tersebut dianggap baik. Untuk nilai yang berkisar antara 20% hingga 50%, peramalan dinyatakan layak. Namun, jika nilai MAPE lebih dari 50%, peramalan tersebut dianggap kurang akurat. Klasifikasi ini memberikan gambaran yang jelas tentang kualitas peramalan yang akan digunakan dan diharapkan dalam konteks penelitian ini. Meskipun terdapat perbedaan konsep antara peramalan dengan prediksi yang bersifat umum, pendekatan klasifikasi ini digunakan karena memiliki tujuan yang sama, yakni meminimalkan selisih atau *error* antara nilai yang dihasilkan oleh model dengan nilai aktual dengan menggunakan MAPE yang mengukur persentase kesalahan rata-rata absolutnya. Sehingga, pendekatan klasifikasi dalam penelitian ini untuk mengukur seberapa baik performa model ANN dalam memberikan penilaian yang objektif terhadap keandalan model dalam mendeteksi hubungan antara parameter *input* geoteknik dengan *output* nilai keamanan lereng (SF).

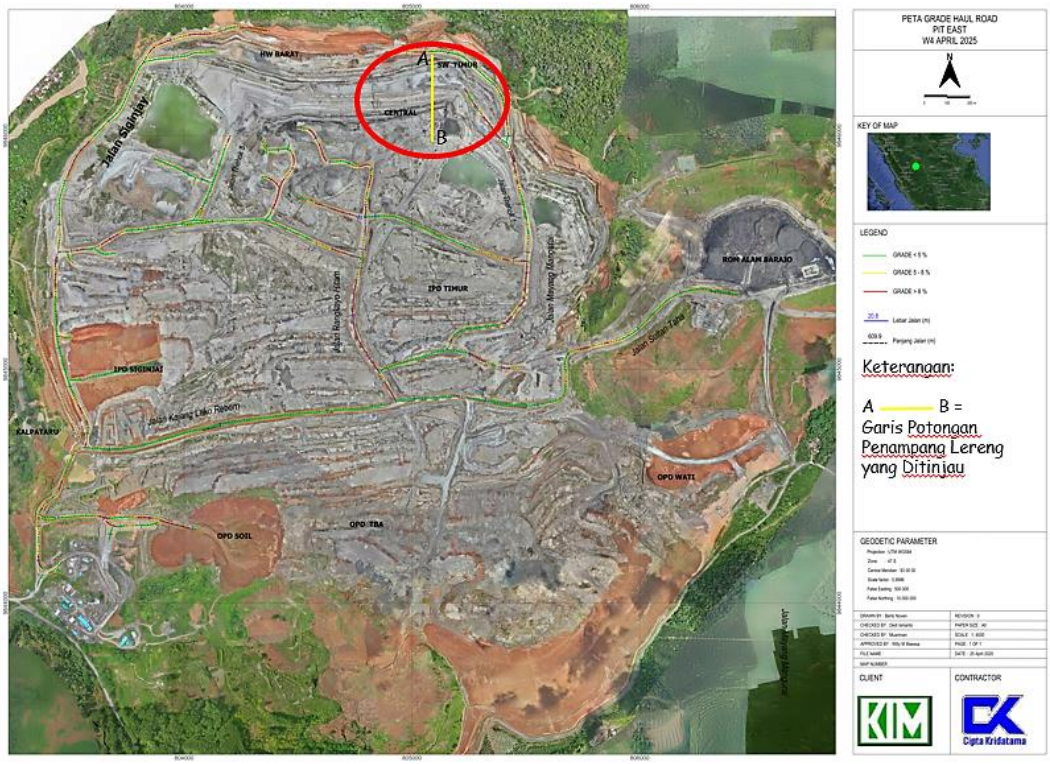
BAB IV
METODE PENELITIAN

4.1 Tinjauan Umum

Analisis pada penelitian ini menggunakan metode yang digunakan untuk optimalisasi nilai keamanan lereng (SF) pada proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi dengan mengadopsi pendekatan pemodelan *Artificial Neural Network* (ANN) yang akan dijalankan dengan bantuan bahasa pemrograman Python melalui *Visual Studio Code* dengan *environment/requirements*: Anaconda versi 24.9.2 dan Python *Interpreter* 3.10.11. Metode ini dirancang untuk menganalisis dan memberikan gambaran yang akurat dengan memasukkan parameter-parameter data *input* geoteknik (data tanah dan lereng) pertambangan terhadap stabilitas lereng ataupun yang mempengaruhi nilai keamanan lereng (SF) tersebut.

4.2 Subjek dan Objek Penelitian

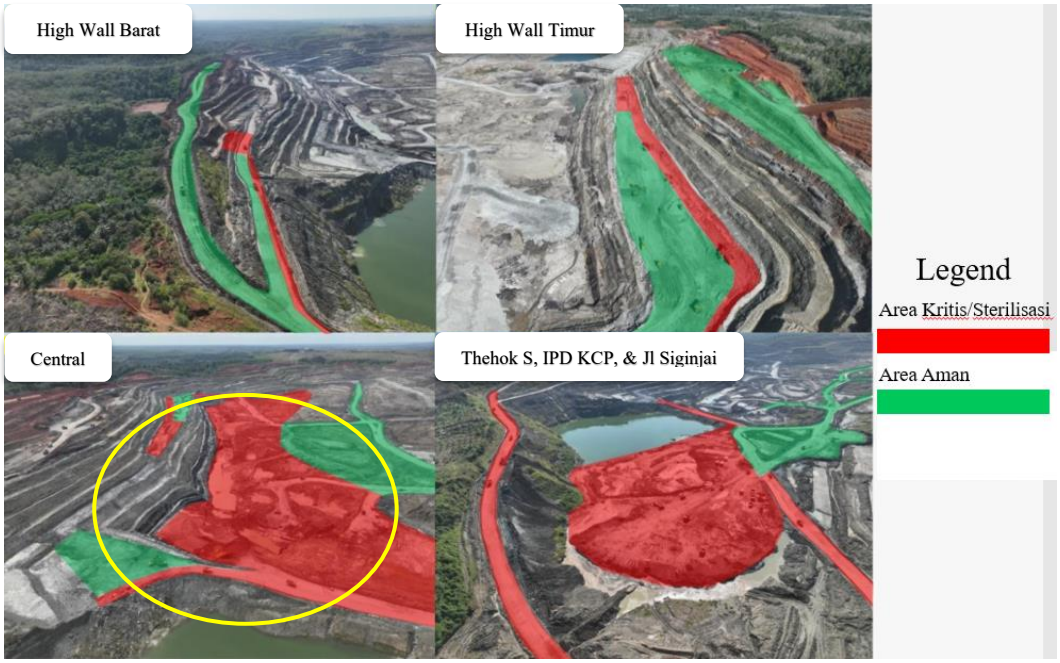
Berdasarkan yang dijelaskan di atas, subjek dari penelitian ini adalah optimalisasi nilai keamanan lereng (SF) dengan target SF 1.25 sebagai syarat nilai keamanan lereng (SF), dengan menggunakan pemodelan *Artificial Neural Network* (ANN) sebagai metode analisis dalam mengolah data yang dibantu dengan bahasa pemrograman Python untuk memperoleh hasil atau *output* dengan memasukkan parameter-parameter tanah dan lereng yang tersedia dari objek penelitian, yaitu menggunakan data-data tanah dan geometri lereng berdasarkan 1 potongan lereng yang berada pada bagian utara, *central* PIT proyek pertambangan PT Cipta Kridatama, di Dusun Tanjung Belit, Provinsi Jambi. Adapun lokasi dari objek penelitian ini dapat dilihat pada Gambar 4.1, Gambar 4.2 dan Gambar 4.3 sebagai berikut.



Gambar 4.1 Peta Lokasi Penelitian



Gambar 4.2 Potongan Penampang Lereng yang Ditinjau (Bagian Utara, *Central* PIT)



Gambar 4.3 Peta Area Kritis Lokasi Penelitian

Gambar 4.1 merupakan peta lokasi dari objek lereng penelitian yang ditinjau yang berada pada bagian utara, *central* PIT dimana apabila dilihat dengan menggunakan foto drone yang dilakukan oleh *geotechnical engineering* PT Cipta Kridatama, maka akan tampak potongan penampang lereng yang diperbesar pada Gambar 4.2 yang diambil pada tanggal 14 Mei 2025. Lereng tersebut pernah terjadi longsor (*vatality*) pada tahun 2022 yang sangat berakibat fatal dan merugikan bagi proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi. Terbukti pada Gambar 4.3 yang merupakan peta area kritis yang dibuat oleh tim *geotechnical engineering* PT Cipta Kridatama pada bulan Mei tahun 2025, pada bagian utara, *central* PIT yang merupakan lokasi dari objek lereng yang ditinjau juga masih berwarna merah atau dengan kata lain area lereng tersebut masih kritis atau menjadi area sterilisasi.

Mengacu pada kajiann-kajian *geotechnical engineering*, longsor tersebut terjadi disebabkan oleh beberapa faktor seperti geometri lereng yang tinggi (*single slope* yang mencapai 15-20 meter), lereng dengan sudut kemiringan yang curam (60-70)°, serta cuaca hujan yang pada saat itu sangat tinggi atau sedang terjadi hujan deras sehingga muka air tanah (MAT) naik yang mengakibatkan lereng menjadi

rawan longsor. Selain itu, pada bagian *side wall* PIT juga ada lereng yang terkena sesar atau kekar sehingga lereng tersebut merupakan zona aktif yang rawan bergerak. Oleh karena itu, penelitian ini juga mengkaji ulang nilai keamanan lereng (SF) beserta geometri lereng yang terletak pada bagian utara, *central* PIT tersebut dimana variasi dari geometri lereng yang dibuat telah menyesuaikan dan mengacu pada persyaratan yang digunakan oleh proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi seperti ketinggian lereng yang dianalisis dan dianggap menjadi *single slope* adalah lereng dengan ketinggian yang lebih dari 10 meter, variasi sudut kemiringan lereng (α) yang digunakan berada pada *range* 20° - 50°, dan juga kondisi muka air tanah (MAT) dianggap berada di permukaan yang berarti lereng berada dalam kondisi terburuk (jenuh air) yang dapat meningkatkan tekanan air pori (*pore water pressure*) sehingga menyebabkan ketidakstabilan pada lereng.

4.3 Peraturan dan Standar yang Digunakan

Adapun peraturan dan standar dalam penelitian ini mengacu pada metode ataupun pedoman-pedoman yang digunakan di proyek pertambangan PT Cipta Kridatama, *site* Jambi antara lain sebagai berikut.

1. Keputusan Menteri Energi dan Sumber Daya Mineral (ESDM) Republik Indonesia Nomor 1827 K/30/MEM/2018 tentang Pedoman Pelaksanaan Kaidah Teknik Pertambangan yang Baik.
2. Pedoman Konstruksi dan Bangunan (Departemen Pekerjaan Umum): Rekayasa Penanganan Keruntuhan Lereng pada Tanah Residual dan Batuan Pd T-09-2005-B.
3. Dokumen Kuansing Inti Makmur: KIM-MED-POS-002-R02-Pembuatan Design PIT.
4. Dokumen Kuansing Inti Makmur: KIM-MED-PPO-021-R01-Pembuatan Geotechnical Memorandum.
5. Dokumen Kuansing Inti Makmur: KIM-MED-PPO-020-R01-Pemantauan Lereng Tambang.

6. Kajian-kajian tim *geotechnical engineering* PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi.

4.4 Data Penelitian dan Metode Pengumpulan Data

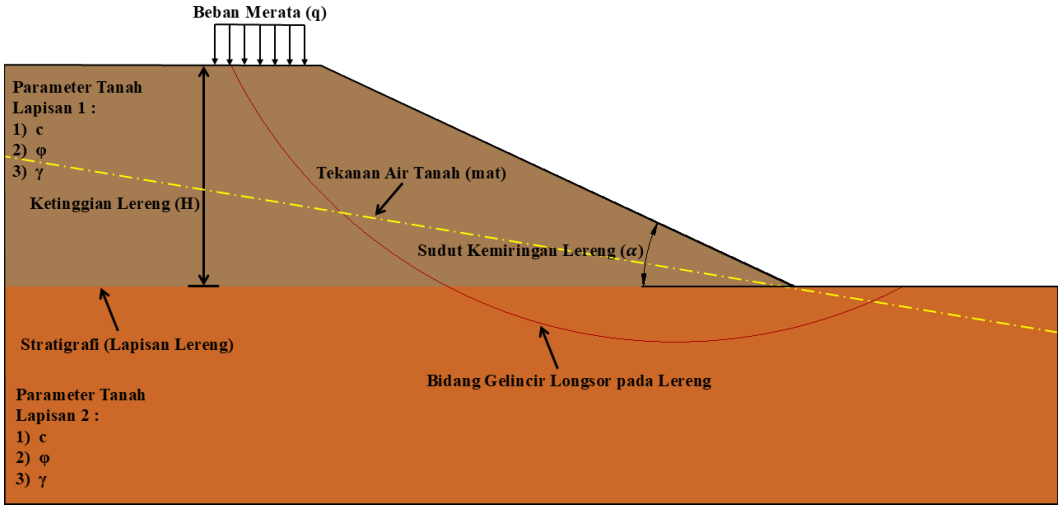
Data yang dikumpulkan dalam penelitian ini terbagi menjadi dua jenis, yakni data utama dan data pendukung. Data utama adalah data yang menjadi fokus utama penelitian dan besumber dari *dataset* yang relevan dengan tujuan penelitian. Sementara itu, data pendukung adalah informasi tambahan yang mendukung analisis dan interpretasi hasil.

1. Data Utama

   Pengumpulan data pada penelitian ini menggunakan beberapa data analisis yang sesuai dengan kondisi lereng yang ada di proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi. Pada penelitian ini data yang digunakan berupa data primer yang berasal dari hasil pengukuran geometri lereng dan data-data tanah yang telah dilakukan oleh PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi. Adapun proses penelitian dimulai dengan pengumpulan data-data geoteknik yang relevan untuk menganalisis nilai keamanan lereng (SF), antara lain:

   a. Data tanah yang terdiri dari:
      1) Nilai kohesi tanah (c);
      2) Sudut geser dalam (φ);
      3) Berat volume tanah (γ).
   b. Topografi lereng yang terdiri dari:
      1) Ketinggian lereng (H);
      2) Sudut kemiringan lereng (α).
   c. Stratigrafi lereng (lapisan lereng),
   d. Muka air tanah (MAT), dan
   e. Beban merata (q).

   Adapun parameter-parameter data di atas dapat terlihat seperti pada Gambar 4.4 di bawah ini.



Gambar 4.4 Ilustrasi Lereng

2. Data Pendukung

   Data pendukung dalam penelitian ini meliputi informasi-informasi tambahan seperti:

   a. Studi literatur yang relevan mengenai pemodelan atau arsitektur *Artificial Neural Network* (ANN), khususnya terkait optimalisasi nilai keamanan lereng (SF) pada proyek pertambangan.
   b. Pedoman acuan ataupun persyaratan yang digunakan untuk membuat variabel optimalisasi model.

4.5 Alat

Peralatan yang digunakan dalam penelitian ini adalah program perangkat lunak ataupun aplikasi komputer. Berikut adalah peralatan yang dibutuhkan dalam penelitian ini sebagai berikut.

1. *Software* AutoCad, yang digunakan untuk membuat potongan penampang lereng yang ditinjau dalam bentuk dua dimensi dan juga untuk mengubah geometri lereng dari lereng asli menjadi banyak model dengan sudut kemiringan lereng (α) yang divariasikan, beserta ketinggian dan lebar *bench* yang mengacu pada persyaratan yang digunakan.

2. *Software* GeoStudio, yang digunakan untuk menganalisis nilai keamanan lereng (SF) dan memberikan gambaran bidang gelincir dengan memasukkan parameter-parameter tanah dan lereng yang tersedia.
3. *Microsoft* Excel, yang digunakan untuk merekapitulasi parameter-parameter data tanah dan lereng beserta nilai keamanan lereng (SF) dari masing-masing model yang telah divariasikan yang digunakan sebagai data *input* dengan format .csv untuk pemodelan ANN nantinya.
4. *Software* Visual Studio Code, yang digunakan untuk membuat arsitektural dan model ANN untuk optimalisasi nilai keamanan lereng (SF) berdasarkan variasi sudut kemiringan lereng (α) dan parameter-parameter yang telah di input.
5. Anaconda versi 24.9.2 dan Python *Interpreter* 3.10.11, yang digunakan sebagai *environment* atau *requirements* dalam memanggil banyak pustaka-pustaka (*library*) yang digunakan untuk menjalankan fungsi-fungsi aktivasi yang dilakukan dengan bahasa pemrograman Python.

4.6 Pelaksanaan Penelitian

Pelaksanaan penelitian penting untuk dilakukan guna mencari rangka yang runtut dalam mempermudah proses pemecahan masalah mengenai data, metode, ataupun teori yang digunakan. Adapun proses pelaksanaan penelitian ini antara lain meliputi hal-hal sebagai berikut.

4.6.1 Studi Literatur

Studi literatur dilakukan dengan mengumpulkan parameter-parameter data atau rumus relevan yang berhubungan dengan optimalisasi nilai keamanan lereng (SF), termasuk metode yang digunakan seperti metode *Fellenius*. Kajian-kajian lainnya yang dikumpulkan juga termasuk pemahaman mengenai arsitektur ANN dan bagaimana model ANN dalam bekerja, sehingga model akan mendapatkan angka prediksi dalam optimalisasi nilai keamanan lereng (SF) nantinya dengan keakuratan output yang tinggi dan jelas (nilai *error* yang kecil) yang dibuktikan dengan *loss function* seperti RMSE, R^2, ataupun MAPE.

4.6.2 Pengumpulan Data

Pengumpulan data pada penelitian ini menggunakan beberapa data analisis yang sesuai dengan kondisi lereng yang ada di proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi. Pada penelitian ini data yang digunakan berupa data primer yang berasal dari hasil pengukuran geometri lereng dan data-data tanah yang telah dilakukan oleh PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi, seperti yang tertera pada sub-bab 4.4.

Setelah data-data parameter tersebut diperoleh, kemudian dibuat model lereng dengan banyaknya variasi sudut kemiringan (α) dengan mengubah geometri lereng aslinya yang mengacu pada persyaratan proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi yang digunakan yakni sudut kemiringan yang digunakan berada pada *range* 20°-50° dengan masing-masing *bench* dibuat 10 meter.

Model lereng dengan berbagai parameter-parameter tanah dengan variasi model berdasarkan sudut kemiringan (α) yang divariasikan tersebut berjumlah 187 data dari 31 variasi model lereng berdasarkan masing-masing *inter-ramp* (batas jenjang) nya, yang diharapkan dapat memberikan gambaran yang komprehensif dan jelas untuk mengetahui berapa kemiringan lereng yang aman dalam memprediksi nilai keamanan lereng (SF) optimal yang mengarah pada SF 1.25 nantinya.

Dataset tersebut kemudian diolah melalui pendekatan model ANN dengan bantuan bahasa pemrograman Python yang diaplikasikan melalui *software* Visual Studio Code sebagai *platform* untuk membuat dan mendapatkan arsitektur ANN dalam melakukan optimalisasi nilai keamanan lereng (SF). Kemudian, model terbaik yang didapatkan nantinya akan digunakan sebagai pertimbangan dan rekomendasi.

4.6.3 *Explotatory Data Analysis* (EDA)

Proses awal dalam analisis data dilakukan dengan EDA untuk memperoleh pemahaman mengenai karakteristik, pola, serta hubungan yang terdapat di dalam *dataset*. EDA akan membantu memperoleh pemahaman awal tentang data seperti distribusi, tren, dan pola dalam data sebelum menerapkan model yang lebih

kompleks, seperti pendekatan histogram dengan membuat grafik berdasarkan data yang telah disusun dalam tabel distribusi frekuensi. EDA pada penelitian ini menggunakan pendekatan analisis deskriptif yang dimana dilakukan perhitungan pada nilai mean, median, dan juga modus untuk setiap variabel.

4.6.4 *Data Preprocessing*

Data preprocessing merupakan tahap yang sangat penting dalam analisis dan pembelajaran oleh mesin yang nantinya akan dilakukan oleh ANN. Sebelum dibuat model ANN untuk menganalisis, diperlukannya persiapan serta transformasi data mentah menjadi format data yang lebih terstruktur dan siap. Proses ini tidak hanya meningkatkan kualitas serta akurasi dari data, akan tetapi juga memastikan data dapat digunakan secara efektif dalam pembelajaran mesin.

Pada penelitian ini data terlebih dahulu dilakukan penanganan *missing value*, yang meliputi menghapus data yang hilang, mengisi dengan nilai rata-rata atau median, menggunakan modus, dan mengisi dengan informasi yang tersedia atau sebagainya. Kemudian data selanjutnya dinormalisasi atau diproses untuk mengubah variabel dalam *dataset* ke dalam skala tertentu, sehingga semua variabel memiliki rentang nilai yang seimbang dan seragam. Normalisasi data ini menggunakan pustaka seperti *sklearn.preprocessing* untuk memanggil *MinMaxScaler*. Selanjutnya data kemudian dibagi (*splitting data*) untuk melatih dan menguji model. Tujuannya adalah untuk menciptakan *dataset* yang dapat digunakan dalam pelatihan model serta langsung mengevaluasi kinerjanya. Hal ini memastikan model mampu melakukan generalisasi terhadap data yang belum pernah dilihat sebelumnya. Porsi terbesar dialokasikan untuk data *training*, yang digunakan dalam melatih dan mendefinisikan parameter model. Sementara, data *testing* akan berfungsi dalam memeriksa keakuratan model terhadap data yang tidak termasuk dalam sampel pelatihannya. Adapun model ANN pada penelitian ini akan dibagi menjadi 80% data pelatihan dan 20% data pengujian, dengan pustaka seperti *sklearn.model selection* untuk memanggil *train_test_split*.

4.6.5 Proses *Input* Data Geoteknik pada ANN

Seperti yang telah dijelaskan pada sub-bab 4.4, data *input* pada pemodelan ANN yang akan digunakan nantinya adalah parameter-parameter tanah dan lereng dengan beberapa variasi sudut kemiringan lereng (α) yang dibuat dari *range* sudut 20°-50° yang mengacu pada persyaratan proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi. Data-data yang berjumlah 187 dari 31 variasi kemiringan lereng tersebut dimasukkan ke dalam *dataset* dengan format excel .csv, yang selanjutnya data-data tersebut akan dilatih dan diuji pada model ANN yang dibuat.

4.6.6 Pembuatan Arsitektur dan Pemodelan ANN

Arsitektur dan pemodelan ANN akan dibuat menggunakan algoritma *backpropagation* (BP) dan fungsi-fungsi aktivasi pengkodingan ANN yang akan dijelaskan sebagai berikut.

1. Menentukan *Hyperparameter* ANN

   Pemilihan *hyperparameter* yang tepat dalam membuat arsitektur ANN tentu akan sangat mempengaruhi kinerja dari model ANN, seperti jumlah lapis dan neuron pada *hidden layer*, yang menjadi hal utama dalam membangun model ANN. Penelitian ini menggunakan *hyperparameter* atau fungsi aktivasi ReLU (*Rectified Linear Unit*) untuk mengenali hubungan non-linearitas dalam model sehingga model akan bisa mempelajari pola yang kompleks serta membantu mengurangi masalah gradien yang hilang selama pelatihan model. Selain itu, *hyperparameter* lain seperti metode optimalisasi, ukuran *batch*, dan jumlah *epochs* juga membantu dalam mendapatkan kinerja model yang optimal.

2. Pelatihan Model ANN

   Berdasarkan persentase yang digunakan untuk data *training* dan *testing* yakni 80% pelatihan dan 20% pengujian yang dilakukan secara *random*, akan menghasilkan nilai *error* dari RMSE, R^2, dan MAPE yang terkecil berdasarkan nilai *loss function* dari masing-masing metrik. Hasil *training* dianggap baik dan memadai apabila tampilan performa model dalam grafik

menunjukkan garis *validation* dengan garis *testing* dari *history* pelatihan memiliki garis konsisten menurun yang hampir sama.

3. Validasi Perhitungan

   Validasi perhitungan bergantung dari nilai yang dikeluarkan oleh metrik yang digunakan, dengan nilai R^2 lebih besar dari 90%, nilai MAPE di bawah 10% serta nilai RMSE yang kecil.

4.6.7 Pembahasan dan Kesimpulan

Tahap akhir dari penelitian ini adalah mengumpulkan seluruh data yang telah dianalisis untuk disusun menjadi sebuah kesimpulan yang sesuai dengan tujuan penelitian, dimana *output* atau hasil yang diperoleh dari model terbaik ANN dalam membuat prediksi untuk optimalisasi nilai keamanan lereng (SF) dengan sudut kemiringan yang aman akan dapat digunakan sebagai pertimbangan atau rekomendasi.

4.7 Analisis Data

Analisis data pada penelitian ini dilakukan dengan menggunakan *software* GeoStudio untuk menganalisis nilai keamanan lereng (SF) dan memberikan gambaran bidang gelincir dengan memasukkan data-data *input* berupa data tanah, topografi lereng, dan stratigrafi (lapisan lereng) dengan menggunakan metode-metode analisis stabilisasi lereng yakni *Slope/W* dengan pendekatan keseimbangan batas (*limit equilibrium*) yang dianalisis dengan tipe metode analisis *Fellenius*. *Artificial Neural Network* (ANN) dalam tahap pengembangan, pelatihan, pengujian hingga evaluasi model dibantu oleh pengkodingan dari pemrograman Python yang ditranskrip dengan *software Visual Studio Code*. Berikut merupakan langkah-langkah yang akan dilakukan dalam penelitian ini antara lain:

1. Dari kontur lokasi proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi diberikan lokasi tinjauan penelitian yang kemudian dibuat tampak potongan penampang lereng untuk digunakan sebagai acuan lereng asli dengan variasi sudut kemiringan lereng (α) yang asli.

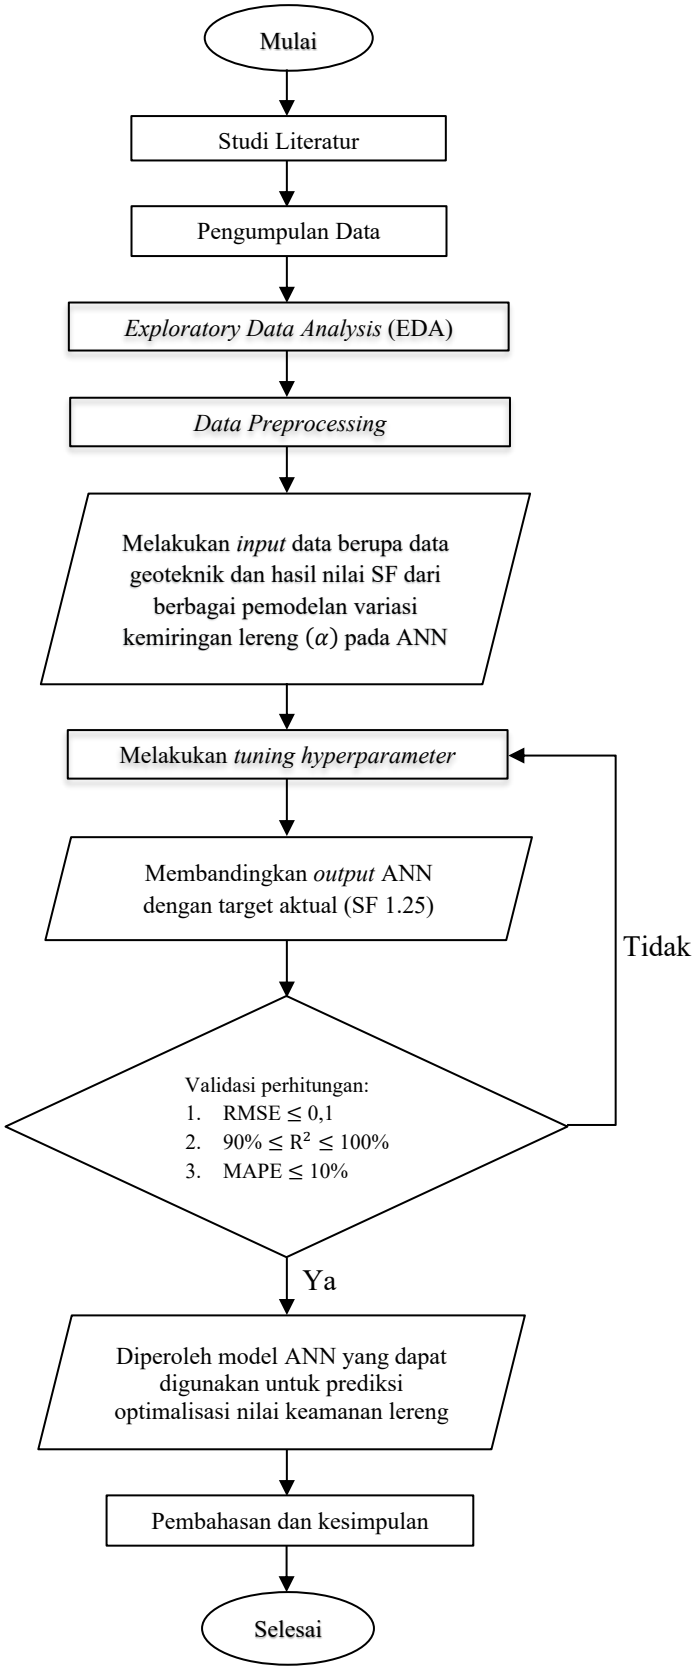
2. Dari acuan lereng asli tersebut, selanjutnya dibuat variasi sudut kemiringan lereng (α) yang mengacu pada persyaratan yang digunakan serta pertimbangan kajian-kajian *geotechnical engineering* PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi, seperti lebar *bench* yang digunakan, beban merata (q) pada lereng tersebut, dan lainnya.
3. Data-data tanah dan geometri lereng yang diberikan dari lokasi tinjauan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi kemudian akan diolah dan dimasukkan ke dalam *software* GeoStudio untuk dianalisis melalui *Slope/W* dengan pendekatan keseimbangan batas (*limit equilibrium*) dan dianalisis menggunakan tipe analisis metode *Fellenius* untuk memberikan hasil dan gambaran bidang gelincir dan nilai keamanan lereng (SF) dari setiap variasi sudut kemiringan lereng (α) yang dimasukkan, yang selanjutnya semua hasil dari nilai keamanan lereng (SF) tersebut akan menjadi *input data layer* dalam pengembangan model ANN nantinya.
4. Tahapan pengembangan model ANN dilakukan dengan membuat arsitektur dan mengembangkan variabel-variabel ANN dari data-data sebelumnya yang didapat. Model ANN tersebut nantinya akan dibangun dengan *Multilayer Perceptron* (MLP) yang terdiri dari 1 lapisan masukan (*input layers*) yang di dalamnya ada 7 parameter data himpunan dimana berisikan variabel bebas yakni nilai kohesi tanah (c), sudut geser dalam (φ), berat volume tanah (γ), ketinggian lereng (H), muka air tanah (MAT), dan beban merata (q), serta variabel terikat yakni sudut kemiringan lereng (α) dan nilai keamanan lereng (SF), kemudian 3 lapisan tersembunyi (*hidden layers*) yang terdiri dari 30, 20 dan 10 neuron yang masing-masing melakukan perhitungan berbasis bobot dan bias, dan 1 lapisan hasil (*output layer*), karena fungsi dan tugasnya sebagai regresi yaitu untuk optimalisasi nilai keamanan lereng (SF) yang mendekati SF target atau syarat yang digunakan sebesar 1.25. Proses pelatihan model dilakukan dengan menggunakan *hyperparameter* ReLU (*Rectified Linear Unit*) dan Adam (*Adaptive Moment Estimation*) sebagai algoritma optimasi yang stabil, serta algoritma *backpropagation*, yang

dimana bobot dan bias jaringan akan dioptimalkan untuk meminimalkan kesalahan prediksi.

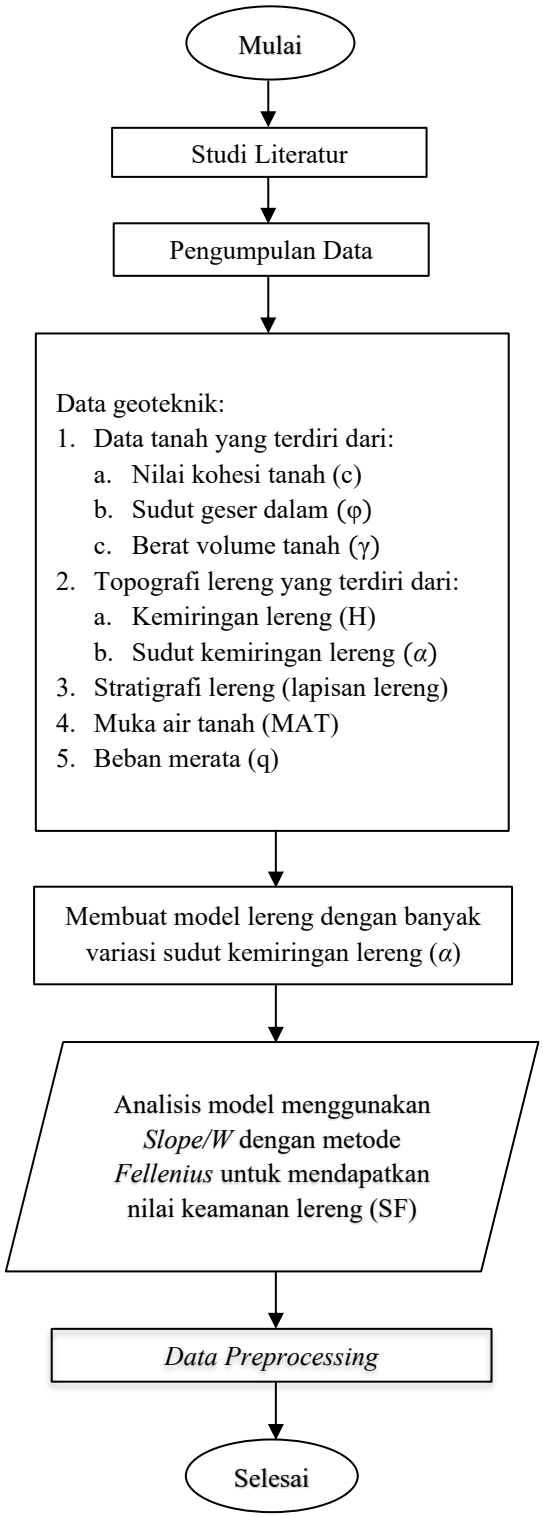
5. *Visual Studio Code* sebagai *platform* untuk implementasi model ANN, dengan *environment*: Anaconda versi 24.9.2 dan Python *Interpreter* 3.10.11 memanfaatkan pustaka (*library*) seperti *TensorFlow* dan *Keras* yang menyediakan alat dan fungsi yang diperlukan untuk membangun dan melatih model jaringan saraf. Proses pelatihan dilakukan dengan membagi *dataset* menjadi dua bagian, yaitu data pelatihan dan data pengujian, dengan proporsi 80% untuk pelatihan dan 20% untuk pengujian. Selama pelatihan, model dievaluasi menggunakan metrik kinerja seperti *Root Mean Square Error* (RMSE) dan koefisien determinasi (R^2) dan *Mean Absolute Persentage Error* (MAPE) untuk memastikan akurasi dan keandalan model.
6. Setelah model ANN dilatih, tahap selanjutnya adalah pengujian model dengan menggunakan data pengujian untuk mengevaluasi kinerja model dan mencari mana model yang terbaik (sudut kemiringan lereng yang aman) dalam memprediksi nilai keamanan lereng yang optimal (SF 1.25) yang nantinya akan digunakan. Hasil prediksi dari model ANN kemudian dibandingkan dengan hasil analisis numerik yang telah dilakukan sebelumnya untuk menilai efektivitas dan akurasi model dalam melakukan optimalisasi nilai keamanan lereng (SF) yang nantinya akan bisa menjadi pertimbangan atau rekomendasi.

4.8 Bagan Alir Penelitian dan *Data Preprocessing*

Bagan alir dalam penelitian ini dibagi menjadi 2, yakni bagan alir penelitian secara keseluruhan dan bagan alir *data preprocessing*, dimana dari masing-masing bagan alir ini berfungsi untuk memberikan gambaran tahap-tahap yang akan dilakukan atau dilalui di dalam penelitian ini. Bagan alir dalam penelitian ini dapat dilihat pada Gambar 4.5 dan Gambar 4.6 di bawah ini.



Gambar 4.5 Bagan Alir Penelitian



Gambar 4.6 Bagan Alir *Data Preprocessing*

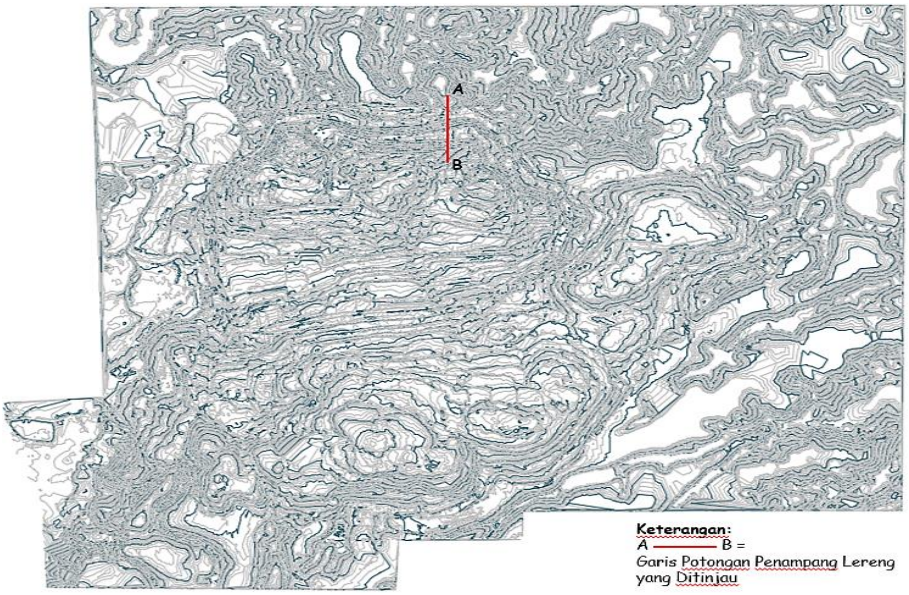
BAB V
ANALISIS DAN PEMBAHASAN

5.1 Pemodelan Lereng

Sebelum data-data geometri lereng diolah, dibuat model potongan penampang lereng asli terlebih dahulu dari lokasi atau area tinjauan penelitian yaitu berdasarkan 1 potongan lereng yang berada pada bagian utara, *central* PIT proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi. Lereng asli tersebut kemudian akan dibuat menjadi beberapa skema atau variasi berdasarkan variabel optimalisasi model yang digunakan dari rumus nilai keamanan lereng (SF) metode *Fellenius* yakni sudut kemiringan lereng (α) yang nantinya dengan variasi tersebut akan dimasukkan parameter tanah dan lereng yang tersedia untuk digunakan dalam optimalisasi nilai keamanan (SF).

5.1.1 Kontur

Model potongan penampang lereng asli diambil dari kontur lokasi tinjauan penelitian. Adapun kontur tersebut dapat dilihat pada Gambar 5.1 sebagai berikut.



Gambar 5.1 Lokasi Tinjauan Penelitian Lereng Asli dari Kontur

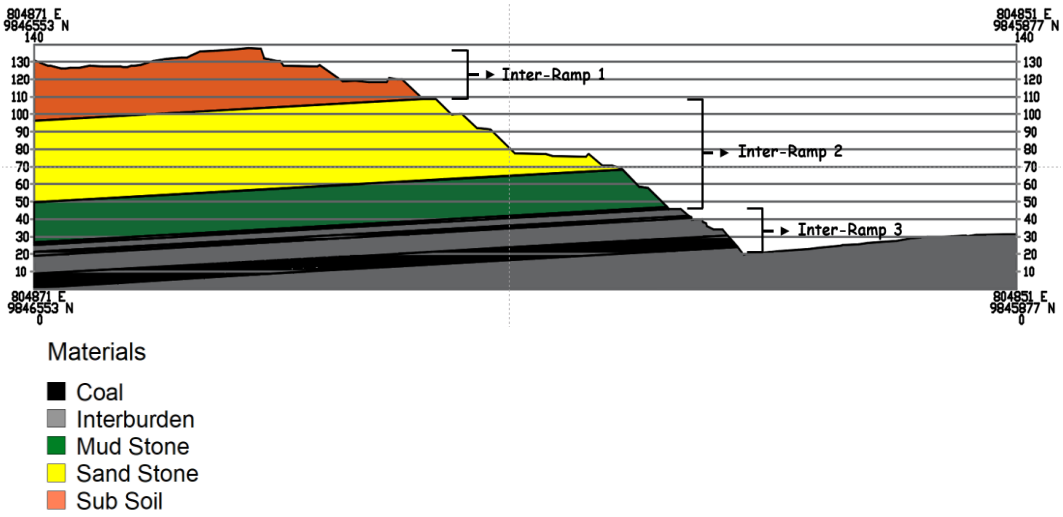
Dari Gambar 5.1 tersebut, potongan penampang lereng A – B dapat dilihat pada Gambar 5.2 di bawah yang dibuat dengan bantuan *software* AutoCad yang dibagi menjadi beberapa *inter-ramp* (batas jenjang) untuk tiap lapisan (stratigrafi) lereng berdasarkan dari ketinggiannya.

5.1.2 *Inter-Ramp*

Inter-ramp (batas jenjang) adalah bagian tubuh lereng tambang terbuka yang terpotong atau berbatasan dengan ramp, yang dimana *inter-ramp* ini terdiri dari beberapa jenjang (*bench*). *Inter-ramp* dapat diartikan juga sebagai sudut lereng gabungan dari beberapa jenjang (*bench*) di antara dua jalan angkut (*haul road*). Dalam hal ini, proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi menggunakan lebar *bench* atau jenjang jalan sepanjang 10 meter.

Di lokasi atau area tinjauan penelitian, bentuk lereng asli ini terdiri dari 10 *single slope* dan lapisan (stratigrafi) lereng yang terdiri dari 5 lapisan yakni diantaranya *sub-soil*, *sand-stone*, *mud-stone*, *coal* dan *interburden*. Kemudian, lapisan-lapisan tersebut dibagi menjadi 3 batas jenjang (*inter-ramp*) berdasarkan dari ketinggiannya yaitu jenjang atas atau *inter-ramp* 1 (131 – 110) meter, jenjang tengah atau *inter-ramp* 2 (110 – 46) meter, serta jenjang bawah atau *inter-ramp* 3 (46 – 0) meter.

Dalam penelitian ini, stratigrafi atau lapisan lereng nantinya akan dianalisis dengan menggunakan parameter-parameter data tanah dan lereng berdasarkan dari 3 batas jenjang (*inter-ramp*) tersebut. Adapun yang termasuk ke dalam *inter-ramp* 1 adalah lapisan *sub-soil* yang berwarna oranye. Kemudian, lapisan pada *inter-ramp* 2 adalah lapisan *sand-stone* yang berwarna kuning, *mud-stone* yang berwarna hijau dan *coal* 100 yang berwarna hitam. Selanjutnya, lapisan pada *inter-ramp* 3 adalah lapisan *interburden* yang berwarna abu-abu, *coal* 200, dan *coal* 300 yang berwarna hitam. Bentuk potongan penampang lereng asli berdasarkan batas jenjang (*inter-ramp*) dari lokasi atau area tinjauan penelitian yang telah dijelaskan di atas dapat dilihat seperti pada Gambar 5.2 di bawah ini.

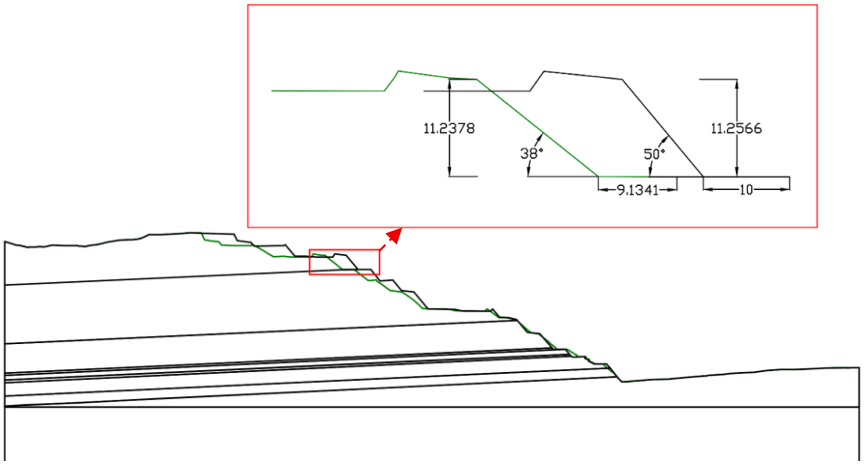


Gambar 5.2 Model Lereng Asli Berdasarkan *Inter-Ramp* (Batas Jenjang)

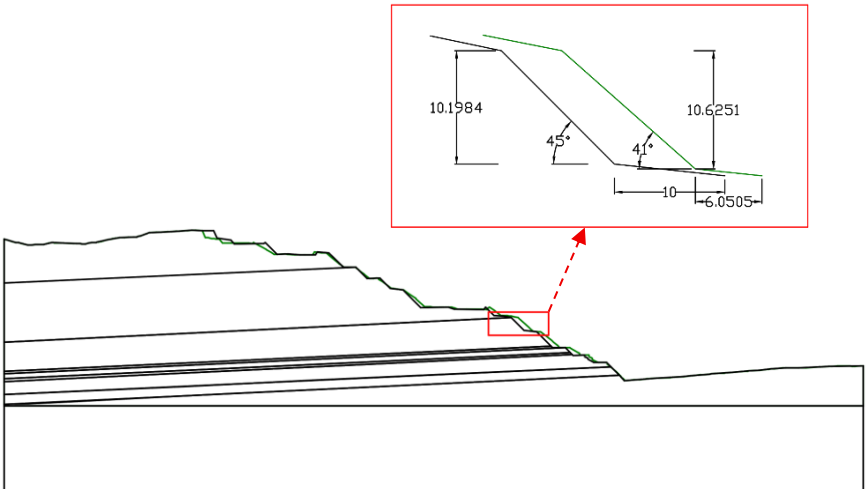
5.1.3 Variasi Model

Setelah terbentuk model lereng asli yang digunakan sebagai acuan, tahap selanjutnya adalah model akan divariasikan atau dibuat beberapa skema berdasarkan variabel optimalisasi model yang digunakan dari rumus nilai keamanan (SF) lereng yakni sudut kemiringan lereng (α). Adapun, pertimbangan dari variasi lereng ini mengacu pada persyaratan dan pedoman yang digunakan di proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi serta kajian-kajian tim *geotechnical engineering* PT Cipta Kridatama seperti lebar *bench* atau jenjang jalan yang dibuat sepanjang 10 meter (diubah dari bentuk geometri lereng aslinya), sudut kemiringan lereng (α) yang divariasikan yakni pada *range* 20 – 50 derajat (digunakan di lapangan) terhadap bentuk geometri dari lereng aslinya, nilai beban merata (q) yang digunakan yakni alat berat HD *Truck* 777 *class* sebesar 58,50 kN/m^2 serta pertimbangan dari tim *geotechnical engineering* jika kondisi terburuk lereng dalam hal ini muka air tanah (MAT) yang dianggap berada di permukaan (kondisi jenuh air).

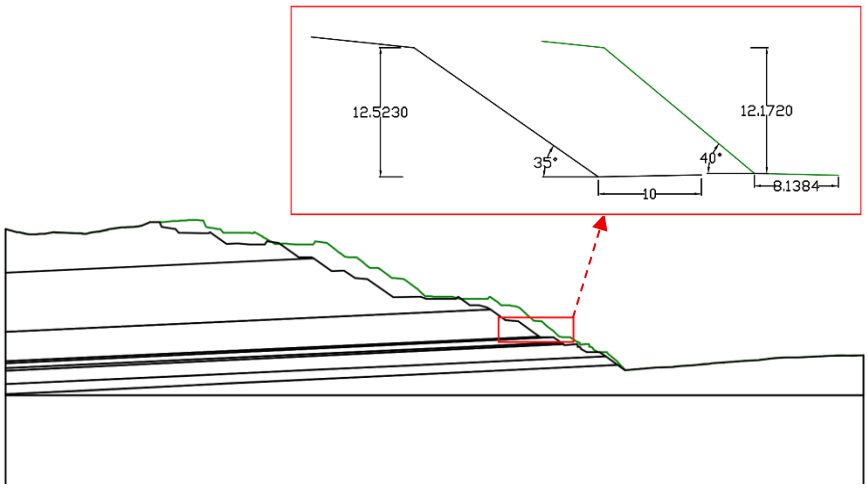
Adapun untuk skema atau variasi model tersebut dapat dilihat seperti pada contoh Gambar 5.3, Gambar 5.4, Gambar 5.5, dan Gambar 5.6 di bawah ini dengan variasi sudut kemiringan lereng (α) 20 – 50 derajat terhadap geometri lereng aslinya.



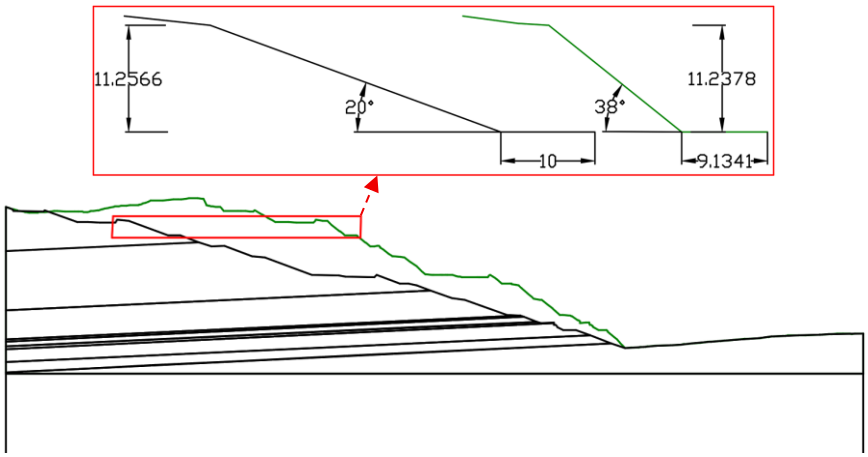
Gambar 5.3 Contoh Model dengan Variasi Sudut Kemiringan (*α*) 50 derajat



Gambar 5.4 Contoh Model dengan Variasi Sudut Kemiringan (*α*) 45 derajat



Gambar 5.5 Contoh Model dengan Variasi Sudut Kemiringan (*α*) 35 derajat



Gambar 5.6 Contoh Model dengan Variasi Sudut Kemiringan (α) 20 derajat

Semua model lereng yang telah dibuat sebanyak 31 variasi sudut kemiringan lereng (α) dari *range* 20 – 50 derajat terhadap lereng aslinya tersebut kemudian di *import* atau dipindahkan dari *software* AutoCad ke *software* GeoStudio untuk nantinya dilakukan analisis nilai keamanan lereng (SF) nya.

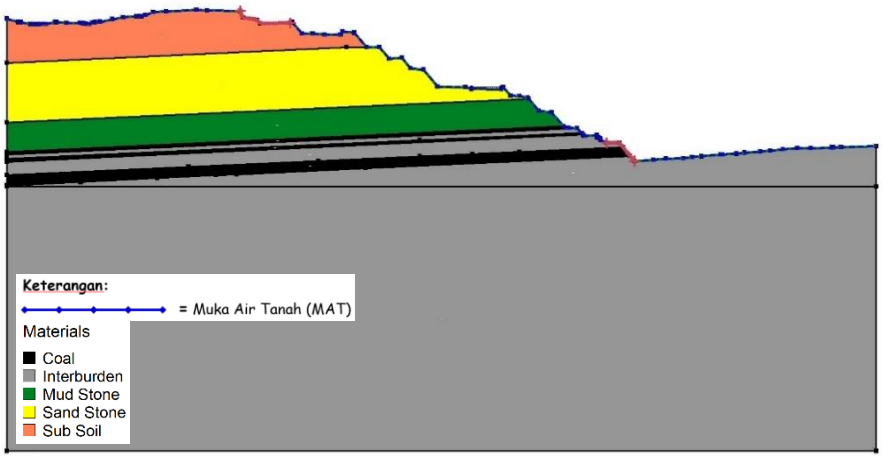
5.1.4 Parameter Tanah dan Lereng

Data parameter tanah dan lereng digunakan sebagai *input* untuk analisis nilai keamanan lereng (SF). Adapun data parameter tanah dan lereng yang digunakan berasal dari lokasi lereng tinjauan di bagian utara, *central* PIT terlampir pada Tabel 5.1 sebagai berikut.

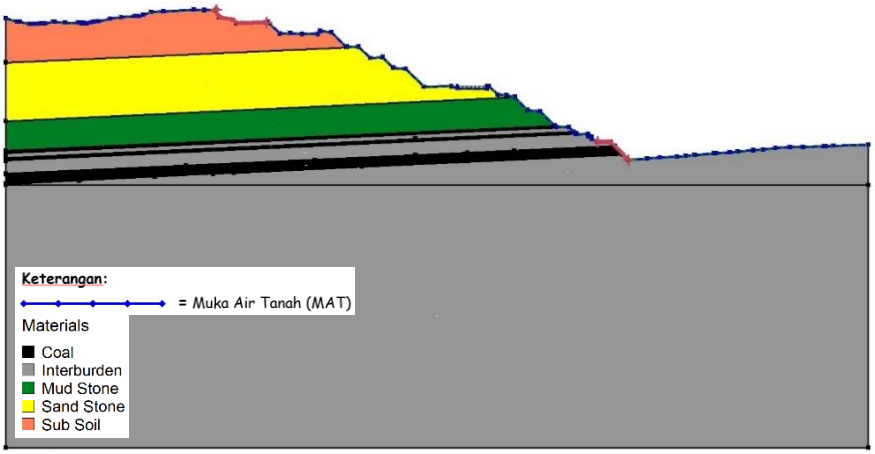
Tabel 5.1 Parameter Tanah dan Lereng pada Lereng yang Ditinjau

Stratigrafi	**Batas Jenjang (m)**	**γ (kN/m^3)**	**c (kPa)**	**φ (°)**	**H (m)**	**MAT (m)**
Sub-Soil	Inter-Ramp 1 (131 – 110)	17,33	4,3	26	34,4205	28,80
Sand-Stone	Inter-Ramp 2 (110 – 46)	22	70,14	31,43	71,3744	62,80
Mud-Stone		22	76,50	32,50	71,3744	62,80
Coal 100		12	176,67	31,67	71,3744	62,80
Coal 200/300	Inter-Ramp 3 (46 – 0)	12	176,67	31,67	24,9944	25,95
Interburden		22	72	30	24,9944	25,95

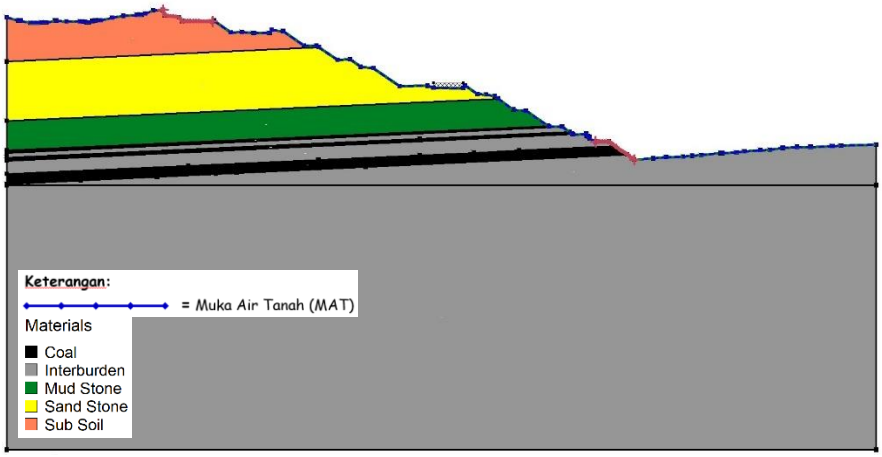
Selanjutnya, data parameter tanah dan lereng di atas dimasukkan ke dalam variasi-variasi model lereng yang telah dibuat di *software* GeoStudio untuk dianalisis nilai keamanan lereng (SF) nya. Setelah data parameter tersebut dimasukkan, variasi-variasi model lereng dapat dilihat seperti pada beberapa contoh Gambar di bawah ini dengan variasi sudut kemiringan lereng (α) 20 – 50 derajat terhadap lereng aslinya.



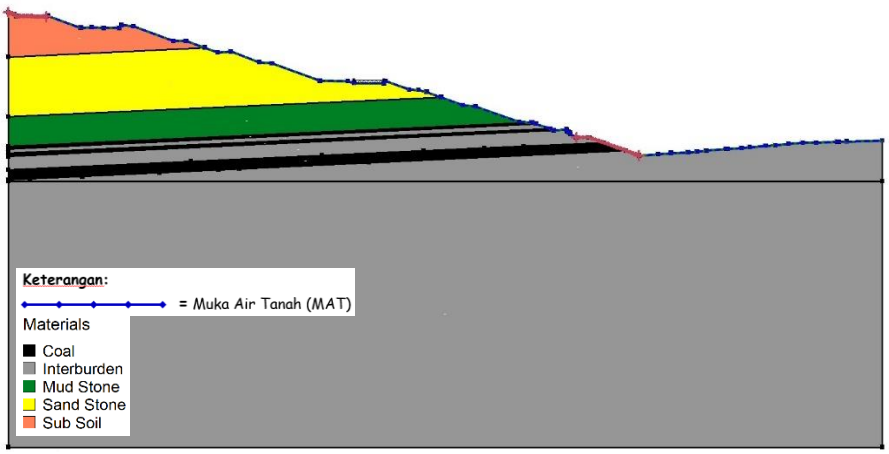
Gambar 5.7 Contoh Model dengan Variasi Sudut Kemiringan (α) 50 derajat yang Telah Dimasukkan Parameter Tanah dan Lereng



Gambar 5.8 Contoh Model dengan Variasi Sudut Kemiringan (α) 45 derajat yang Telah Dimasukkan Parameter Tanah dan Lereng



Gambar 5.9 Contoh Model dengan Variasi Sudut Kemiringan (α) 35 derajat yang Telah Dimasukkan Parameter Tanah dan Lereng

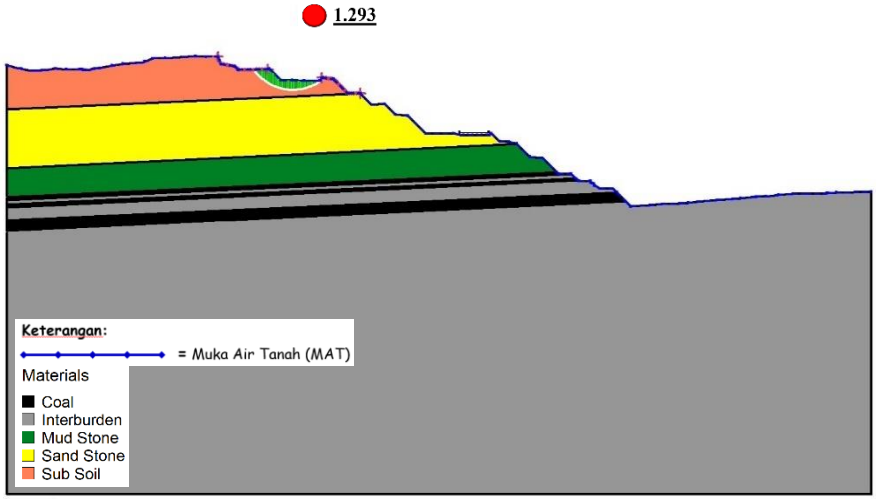


Gambar 5.10 Contoh Model dengan Variasi Sudut Kemiringan (α) 20 derajat yang Telah Dimasukkan Parameter Tanah dan Lereng

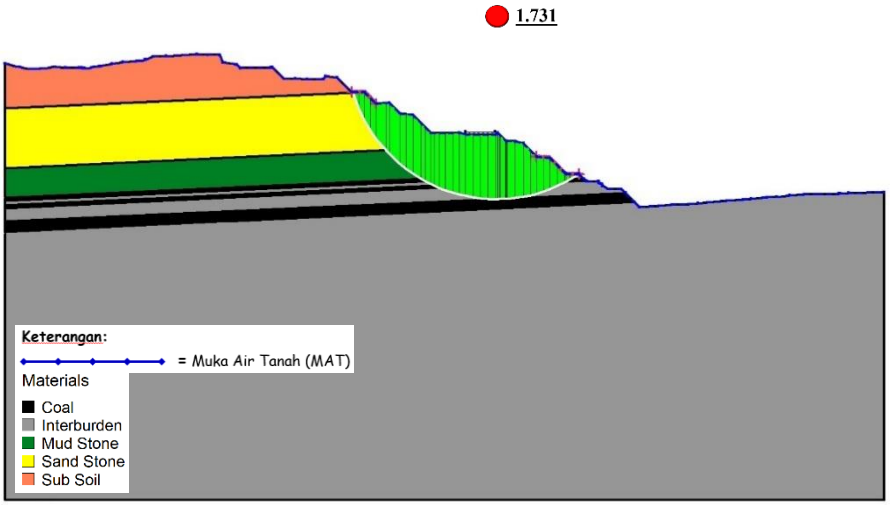
Setelah terbentuk model lereng dengan berbagai variasi sudut kemiringan lereng (α) yang dimasukkan berbagai data parameter tanah dan lereng seperti pada Gambar 5.7, Gambar 5.8, Gambar 5.9, dan Gambar 5.10 di atas, kemudian muka air tanah (MAT) dibuat garis yang berwarna biru seperti pada gambar yang dianggap berada di permukaan lereng, serta beban merata (q) yang diletakkan di atas lereng juga di *input* nilainya sebesar 58,50 kN/m^2.

5.2 Analisis Lereng

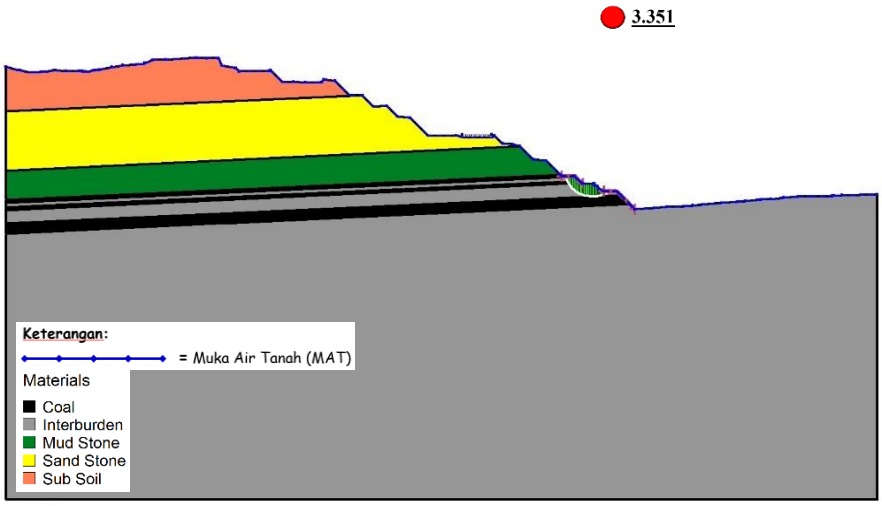
Analisis lereng dilakukan menggunakan *software* GeoStudio melalui *Slope/W* dengan pendekatan keseimbangan batas (*limit equilibrium*) dan dianalisis menggunakan tipe analisis metode *Fellenius* dengan muka air tanah (MAT) dianggap berada di permukaan yang berarti lereng dalam kondisi jenuh air (*fully saturated soil*) dan nilai beban merata (q) yang digunakan yakni 58,50 kN/m^2 (berat beban merata untuk alat berat HD *Truck* 777 *Class*), sehingga setelah data parameter tersebut dimasukkan untuk dianalisis, dilakukan metode pencarian *entry and exit* yang mensimulasikan ribuan kemungkinan bidang gelincir dari masing-masing *inter-ramp* (batas jenjang) nya untuk menghasilkan nilai keamanan lereng (SF) dan juga gambaran bidang gelincirnya seperti yang dicontohkan untuk model lereng dengan sudut kemiringan (α) 45 derajat pada Gambar 5.11, Gambar 5.12, dan Gambar 5.13 di bawah ini dengan analisis yang dilakukan pada *inter-ramp* atas, tengah, dan bawah serta rekapitulasi dari semua analisis nilai keamanan lereng (SF) yang dilakukan di semua variasi sudut kemiringan lereng (α) dari 20 – 50 derajat terhadap lereng aslinya dapat dilihat pada Tabel 5.2 antara lain sebagai berikut.



Gambar 5.11 Contoh Hasil Analisis Nilai Keamanan Lereng (SF) Model dengan Variasi Sudut Kemiringan (α) 45 derajat *Inter-Ramp* Atas



Gambar 5.12 Contoh Hasil Analisis Nilai Keamanan Lereng (SF) Model dengan Variasi Sudut Kemiringan (*α*) 45 derajat *Inter-Ramp* Tengah



Gambar 5.13 Contoh Hasil Analisis Nilai Keamanan Lereng (SF) Model dengan Variasi Sudut Kemiringan (*α*) 45 derajat *Inter-Ramp* Bawah

Tabel 5.2 Rekapitulasi Nilai Keamanan Lereng (SF) dari Variasi Sudut Kemiringan Lereng (*α*) 20 – 50 derajat dengan Analisis Slope/W

No	Variasi Sudut Kemiringan Lereng (*α*) 10 *Single Slope* (°)	Sudut Kemiringan *Inter-Ramp* (°) terhadap Variasi			SF *Inter-Ramp*		
		1	2	3	1	2	3
1	50 derajat	16	24	30	1.233	1.659	3.410
2	49 derajat	16	23	30	1.230	1.695	3.426
3	48 derajat	16	23	29	1.237	1.695	3.414
4	47 derajat	16	23	29	1.282	1.694	3.427

Lanjutan Tabel 5.2 Rekapitulasi Nilai Keamanan Lereng (SF) dari Variasi Sudut Kemiringan Lereng (*α*) 20 – 50 derajat dengan Analisis Slope/W

No	Variasi Sudut Kemiringan Lereng (*α*) 10 *Single Slope* (°)	Sudut Kemiringan *Inter-Ramp* (°) terhadap Variasi			SF *Inter-Ramp*		
		1	2	3	1	2	3
5	46 derajat	16	22	29	1.256	1.718	3.465
6	45 derajat	16	22	29	1.293	1.731	3.351
7	44 derajat	16	22	28	1.270	1.734	3.478
8	43 derajat	16	22	28	1.277	1.768	3.491
9	42 derajat	16	21	27	1.284	1.781	3.507
10	41 derajat	16	21	27	1.291	1.818	3.500
11	40 derajat	15	21	27	1.291	1.807	3.513
12	39 derajat	15	21	26	1.307	1.755	3.538
13	38 derajat	15	20	26	1.320	1.825	3.574
14	37 derajat	15	20	25	1.313	1.847	3.599
15	36 derajat	14	20	25	1.342	1.829	3.613
16	35 derajat	14	19	25	1.353	1.895	3.627
17	34 derajat	14	19	24	1.366	1.862	3.584
18	33 derajat	13	19	24	1.402	1.905	3.714
19	32 derajat	12	18	23	1.394	1.913	3.747
20	31 derajat	12	18	23	1.402	1.896	3.777
21	30 derajat	11	18	22	1.425	1.923	3.802
22	29 derajat	11	17	22	1.428	1.931	3.824
23	28 derajat	11	17	21	1.450	1.962	3.825
24	27 derajat	11	17	21	1.459	1.978	3.851
25	26 derajat	10	16	20	1.485	2.031	3.898
26	25 derajat	9	16	20	1.502	2.057	3.924
27	24 derajat	8	15	19	1.518	2.076	3.946
28	23 derajat	8	15	19	1.524	2.153	3.970
29	22 derajat	8	14	18	1.539	2.235	4.012
30	21 derajat	8	14	18	1.555	2.339	4.036
31	20 derajat	8	14	17	1.586	2.323	4.066

Dari Tabel 5.2 di atas, hasil analisis menggunakan *software* GeoStudio melalui *Slope/W* dengan pendekatan keseimbangan batas (*limit equilibrium*) dan dianalisis menggunakan tipe analisis metode *Fellenius* mendapatkan nilai keamanan lereng (SF) yang melebihi dari target syarat yang digunakan (SF 1.25) yang berada pada *range* sudut kemiringan (*α*) dari 20 – 47 derajat pada *inter-ramp*

atas, sementara untuk *inter-ramp* tengah, dan bawah telah melebihi target syarat SF 1.25 semua.

5.3 Pengembangan Model *Artificial Neural Network* (ANN)

Pada penelitian ini, model ANN dikembangkan dengan bantuan bahasa pemrograman Python yang pengkodingannya dibuat melalui *software* Visual Studio Code sebagai *platform*. Visual Studio Code dapat menjadi pengembang kode yang sangat baik karena menyediakan berbagai fitur yang mendukung berbagai bahasa pemrograman termasuk Python. Adapun pengembangan model ANN dengan pemrograman Python melalui *software* Visual Studio Code ini antara lain sebagai berikut.

1. *Environment/Requirements*

   Environment/requirements adalah kumpulan perangkat keras, perangkat lunak, dan konfigurasi yang digunakan untuk mengembangkan, menguji, dan menjalankan aplikasi atau sistem yang berinteraksi dengan data, yang mencakup berbagai komponen yang mendukung alur kerja data, mulai dari pengembangan hingga hasil.

   Dalam penelitian ini, *environment*/*requirements* yang digunakan yakni Anaconda versi 24.9.2 dan Python *Interpreter* 3.10.11 yang memanggil banyak perangkat pustaka (*library*) yakni seperti *absl-py, astunparse, cachetools, certifi, charset-normalizer, contourpy, cycler, flatbuffers, fonttools, gast, google-auth, google-auth-oauthlib, google-pasta, grpcio, h5py, idna, importlib_metadata, importlib_resources, joblib, keras, Keras-Preprocessing, kiwisolver, libclang, Markdown, MarkupSafe, matplotlib, numpy, oauthlib, opt_einsum, packaging, pandas, pillow, protobuf, pyasn1, pyasn1_modules, pyparsing, python-deteutil, pytz, requests, requests-oauthlib, rsa, scikit-learn, scipy, six, tensorboard, tensorboard-data-server, tensorboard-plugin-wit, tensorflow, tensorflow-estimator, tensorflow-intel, tensorflow-io-gcs-filesystem, termcolor, threadpoolctl, typing_extensions, tzdata, urllib3, Werkzeug, wrapt, dan zipp*. Adapun cara menginstall atau

mengaktifkan *environment*/*requirements* ini adalah dengan terminal *coding pip install -r requirements.txt*.

2. Struktur Model

Struktur pengkodingan *project* yang digunakan dalam model variasi lereng ini adalah sebanyak 6 struktur, antara lain:

a. Data/

Pada struktur data/, data-data parameter yang digunakan sebelumnya terlebih dahulu dibuat dalam bentuk *file* .csv untuk dilakukan *input data layer* sebelum melakukan proses pengkodingan lebih lanjut. Adapun *input data* yang dibuat adalah seperti *ramp*, stratigrafi, c, gamma, phi, α, h, MAT, dan SF. Setelah data-data parameter tersebut dibuat dalam bentuk *file* .csv, simpan dan buat folder khusus *dataset* untuk nantinya dimasukkan ke dalam pemrograman Python agar dapat terbaca saat di *running* di dalam pengkodingan yang dibuat.

b. Preprocessing_data.py

Setelah melakukan proses eksplorasi *dataset*, *dataset* kemudian dilakukan pemeriksaan apakah ada *missing value* pada data-data parameter atau model yang akan dianalisis atau dijalankan nantinya. *Preprocessing* data sangat penting dilakukan dalam proses analisis data dikarenakan data akan menjadi lebih siap sebelum dijalankan untuk menghasilkan hasil yang lebih akurat. Pada tahapan ini, perlu memanggil pustaka-pustaka seperti *pandas*, *numpy*, *sklearn* seperti *sklearn.preprocessing* untuk memahami *missing value* agar data dapat *scaling* atau dinormalisasi satu sama lain. Normalisasi data ini tentu membutuhkan nilai minimum dan maksimum yang digunakan dan dijalankan oleh *sklearn.preprocessing*, seperti 0 untuk nilai minimum dan 1 untuk nilai maksimum. Sehingga, data memiliki rentang dari 0 – 1. Di dalam preprocessing_data.py ini juga dilakukan *split train* atau *test split* dimana *dataset* yang telah dinormalisasi nantinya akan dibagi menjadi dua bagian yakni data pelatihan (*training*) dan data pengujian (*testing*), yakni digunakan 80% untuk pelatihan dan 20% untuk pengujian yang dilakukan secara *random*. Data *training* digunakan untuk

melatih model, sementara data *testing* digunakan untuk mengevaluasi performa model setelah dilatih. Hal ini bertujuan untuk menilai seberapa baik nantinya model dalam melakukan analisis pada data baru yang belum pernah dilihat sebelumnya, sehingga dapat menghindari *overfitting* atau pola yang tidak relevan pada pelatihannya (mengalami gangguan/*noise*) dan memberikan evaluasi yang lebih realistis dikarenakan setelah di uji, hasilnya akan langsung divalidasi sendirinya oleh ANN.

5.4 Pelatihan dan Pengujian Model *Artificial Neural Network* (ANN)

Pelatihan dan pengujian model ANN pada penelitian ini akan dilakukan dengan tahapan-tahapan antara lain sebagai berikut.

1. Tuning *Hyperparameter* (Fungsi Aktivasi)

   Proses pelatihan dan pengujian model nantinya dilakukan dengan menggunakan *hyperparameter* ReLU (*Rectified Linear Unit*) dan Adam (*Adaptive Moment Estimation*) sebagai algoritma optimasi yang stabil, serta algoritma *backpropagation* (BP), yang dimana bobot dan bias jaringan akan dioptimalkan untuk meminimalkan kesalahan prediksi.

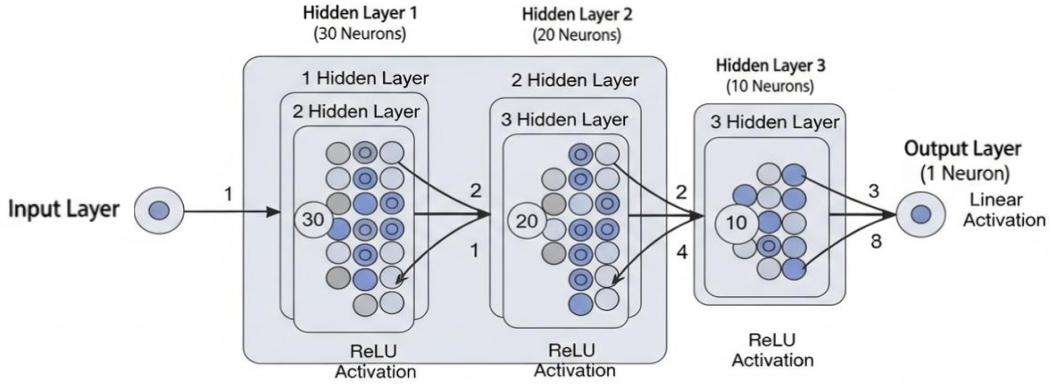
2. Train.py

   Model dilatih dan diuji pada pembelajaran train.py yang dimana model dibuat belajar membaca pola dan memprediksi dari data-data parameter yang di *input* sebelumnya. Pelatihan dan pengujian model dalam pembelajaran ini membagi data menjadi dua *dataset* yakni set pelatihan dan set pengujian, yang dimana 80% untuk pelatihan dan 20% untuk pengujian secara *random*. Pada pembelajaran train.py ini juga model mencari nilai optimal untuk target syarat yang dituju yakni SF 1.25 dan memprediksi sudut kemiringan lereng (α) mana yang paling aman dan terbaik dalam mendekati target SF 1.25 tersebut dari *dataset* yang telah di *input*. Di dalam pembelajaran train.py ini juga *loss function* untuk memvalidasi keakuratan *output* juga menggunakan *rate* kesalahan pembelajaran dalam mengoptimasi sebesar 0,001, sehingga model akan sangat stabil dalam membaca pola dan memprediksi optimal target yang disyaratkan (SF 1.25). Selain itu, *epochs* atau jumlah iterasi yang digunakan

yang dimana model atau seluruh *dataset* melewati 1x proses pembelajaran atau pelatihan ANN sebanyak 100 *epochs*.

3. Arsitektur ANN

Arsitektur ANN pada pemodelan ini memiliki 1 lapisan masukan (*input layer*) yang di dalamnya terdapat 7 parameter data himpunan dimana berisikan variabel-variabel bebas yakni nilai kohesi tanah (c), sudut geser dalam (φ), berat volume tanah (γ), ketinggian lereng (H), muka air tanah (MAT), dan beban merata (q), serta variabel terikat yakni sudut kemiringan lereng (α) dan nilai keamanan lereng (SF), kemudian 3 lapisan tersembunyi (*hidden layers*) yang dimana setiap *hidden layers* ini terdiri dari sejumlah neuron (unit) yang masing-masing melakukan perhitungan berbasis bobot dan bias. Adapun jumlah neuron pada masing-masing atau setiap *hidden layers* yakni *hidden layer* 1 memiliki 30 neuron dengan fungsi aktivasi ReLU, *hidden layer* 2 memiliki 20 neuron dengan fungsi aktivasi ReLU, dan *hidden layer* 3 memiliki 10 neuron dengan fungsi aktivasi ReLU. Alasan pemilihan jumlah 30, 20, dan 10 neuron dengan fungsi aktivasi ReLU pada *hidden layers* ini dikarenakan menyesuaikan dengan kompleksitas data atau banyaknya jumlah data. Lapisan tersembunyi (*hidden layers*) memungkinkan melakukan transformasi yang kompleks pada data masukan (data *input*), sehingga jaringan model akan menangkap pola dan hubungan yang rumit dalam data. Oleh karena itu, digunakan 3 lapisan tersembunyi (*hidden layers*) yang berjumlah masing-masing 30, 20, dan 10 neuron dengan fungsi aktivasi ReLU tersebut disesuaikan dengan jumlah data *input* yang berjumlah 187 data. Kemudian, pada *output layer* hanya memiliki 1 neuron dikarenakan tujuan atau tugasnya yang hanya untuk regresi (satu neuron untuk memprediksi satu nilai tunggal numerik kontinu), sehingga pada *output layer* tidak ada fungsi aktivasi yang diterapkan, maka secara *default* model akan menggunakan *linear activation* (y = x). Adapun *output* yang ingin dihasilkan adalah nilai keamanan lereng (SF) optimal yang mendekati atau sama dengan SF 1.25 dengan *optimize*. Arsitektur ANN yang digunakan pada model dapat dilihat pada Gambar 5.14 di bawah ini.



Gambar 5.14 Arsitektur ANN yang Digunakan

4. Visualization.py

   Sebelum model ANN dijalankan (*running*), *output* yang akan dihasilkan nantinya juga terlebih dahulu dibuat gambaran atau representasi yang dirancang untuk menampilkan data secara visual atau grafis seperti grafik yang memudahkan pemahaman informasi. Melalui visualization.py, model dikodingkan dalam membuat visualisasi data *output* atau hasil, yang dimana memanggil pustaka-pustaka seperti *matplotlib* dan *numpy*. Adapun hasil dari visualisasi nantinya memuat 3 grafik yakni grafik Sudut kemiringan vs SF, grafik *history* pelatihan, dan grafik SF aktual vs prediksi. Grafik Sudut kemiringan vs SF memuat visualisasi bagaimana ANN dalam optimalisasi nilai keamanan lereng yang optimal (target SF 1.25) dengan sudut kemiringan lereng (α) yang masih tetap aman untuk digunakan. Grafik *history* pelatihan memuat visualisasi ANN dalam melakukan proses pelatihan dan validasi prediksi sebanyak 100 *epochs* dengan validasi *loss function* yang berbeda-beda (RMSE, R^2, dan MAPE). Grafik SF aktual vs prediksi memuat visualisasi bagaimana hubungan SF aktual dalam *dataset* dan juga SF prediksi yang dibuat oleh ANN dalam mengoptimalisasi nilai keamanan lereng. Visualization.py ini juga dibuat dalam masing-masing *inter-ramp*.

5. Main.py

   Tahap pelatihan dan pengujian model ANN dijalankan (*running*) dengan main.py, dimana digunakan sebagai titik masuk (*entry point*) dalam program Python. Di kodingan main.py ini, dipanggil tahapan-tahapan pembelajaran

sebelumnya yang sudah dibuat seperti *preprocesing_data*, *train*, *visualization*, untuk dijalankan di dalam main.py ini. Adapun untuk menjalankan main.py ini adalah dengan perintah pada terminal yakni 'python main.py'.

6. Results/

   Semua *dataset* yang telah melewati pelatihan dan pengujian nantinya akan disimpan dalam data hasil prediksi optimalisasi yang dijalankan melalui semua tahapan atau proses dari awal hingga akhir pengkodingan ANN dengan Python hingga sampai pada *result*, berupa hasil dalam gambar grafik, nilai-nilai optimalisasi keamanan lereng (Sudut kemiringan lereng yang aman dengan SF yang optimal), dan juga *test set loss function* (akurasi keakuratan hasil *output*) nya berupa RMSE, R^2, dan MAPE.

5.5 Hasil dan Evaluasi Model *Artificial Neural Network* (ANN)

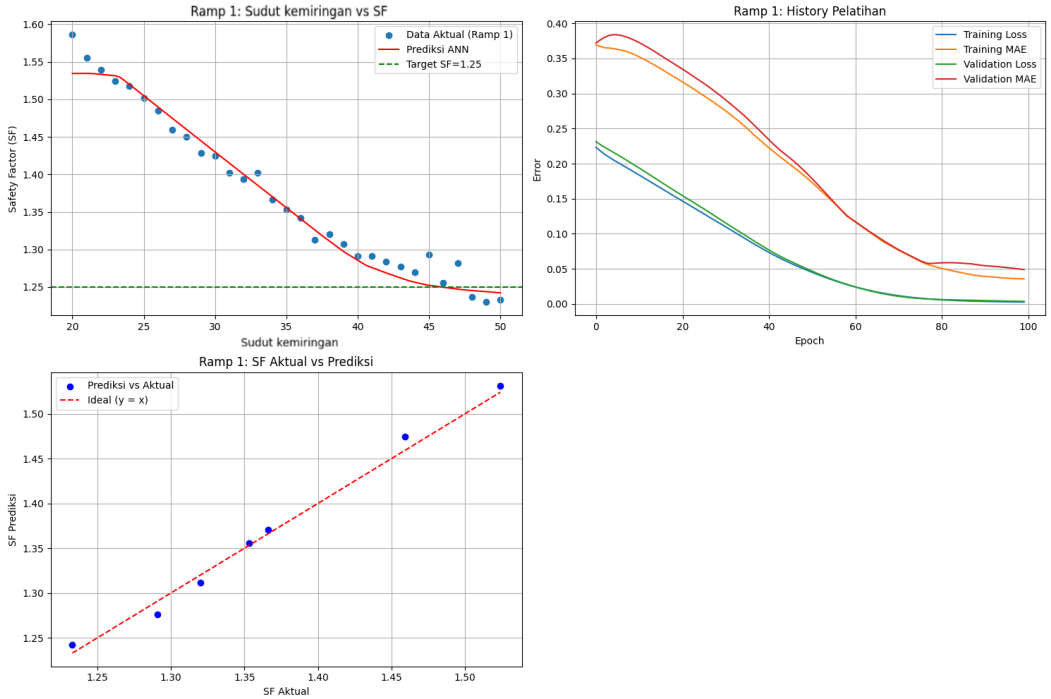
Setelah ANN dijalankan atau di *running* dan sampai pada *results*, maka dicari dan ditemukan model terbaik dari tiap masing-masing *inter-ramp*.

1. Hasil Model Terbaik *Inter-Ramp* Atas

   Dari Gambar 5.15 dan Gambar 5.16 di bawah, nilai keamanan lereng (SF) pada *inter-ramp* 1 (atas) menunjukkan nilai prediksi 1.25 sesuai dengan yang ditargetkan atau di syarat kan (SF 1.25) dengan kemiringan lereng (α) yang aman berada pada kemiringan 46,06 derajat. *History* pelatihan pada *inter-ramp* 1 menunjukkan konsistensi garis linear yang cenderung menurun (*smooth*) menunjukkan bahwa model belajar dengan baik, serta garis linear pelatihan dan validasi berdekatan (tidak terlalu jauh) menunjukkan bahwa model tidak mengalami *overfitting*. *Overfitting* menunjukkan pola yang tidak relevan pada pelatihannya (mengalami gangguan/*noise*) terhadap data baru yang belum pernah dilihat sebelumnya. Hasil dari evaluasi *loss function* untuk akurasi hasil *output* optimalisasi juga menunjukkan nilai *loss* sebesar 0,0008, MAE sebesar $0{,}0254 \leq 0{,}1$ (sangat akurat), RMSE sebesar $0{,}0285 \leq 0{,}1$ (sangat baik), dan R^2 sebesar $0{,}9 \leq 0{,}9879 < 1$ (kuat). Adapun untuk grafik SF aktual vs prediksi, garis prediksi model ANN dengan pemrograman

Python (SF 1.25 dengan sudut kemiringan 46,06 derajat) sangat mendekati SF aktual yang dimana berada pada SF 1.256 pada sudut kemiringan 46 derajat. Sehingga, dapat dikatakan bahwa nilai keamanan lereng (SF) pada *inter-ramp* 1 (atas) ini teroptimalisasi dengan baik oleh model ANN.

Adapun untuk *output* yang didapatkan berupa model terbaik untuk *inter-ramp* atas dapat dilihat seperti pada Gambar 5.15 dan Gambar 5.16 di bawah ini.



Gambar 5.15 Hasil Prediksi ANN Terhadap Optimalisasi Nilai Keamanan Lereng (SF) pada *Inter-Ramp* Atas

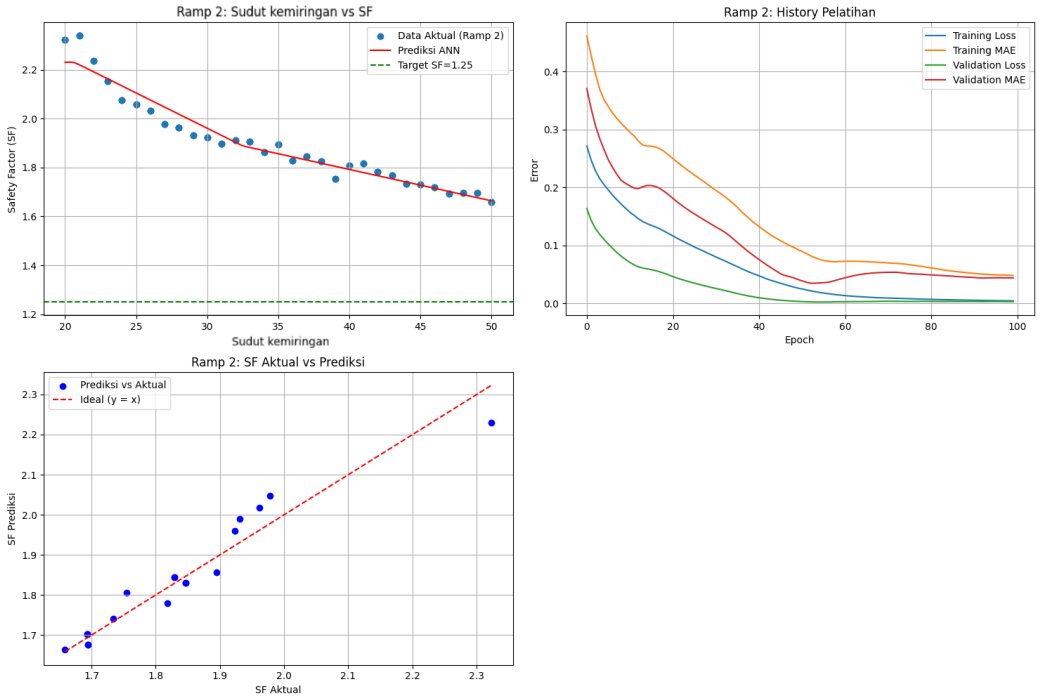
```
Ramp 1:
  a optimal      = 46.06
  Prediksi SF    = 1.2496
  Hasil Evaluasi Test Set:
    loss: 0.0008
    mae: 0.0254
    rmse: 0.0285
    r_squared: 0.9879
```

Gambar 5.16 Akurasi Hasil Model ANN pada *Inter-Ramp* Atas

2. Hasil Model Terbaik *Inter-Ramp* Tengah

Dari Gambar 5.17 dan Gambar 5.18 di bawah, nilai keamanan lereng (SF) pada *inter-ramp* 2 (tengah) menunjukkan nilai prediksi 1.6638 yang mendekati SF yang ditargetkan atau di syarat kan (SF 1.25) dengan kemiringan lereng (α) yang aman berada pada kemiringan 50 derajat. *History* pelatihan pada *inter-ramp* 2 menunjukkan konsistensi garis linear yang cenderung menurun (*smooth*) menunjukkan bahwa model belajar dengan baik, serta garis linear pelatihan dan validasi berdekatan (tidak terlalu jauh) menunjukkan bahwa model tidak mengalami *overfitting*. *Overfitting* menunjukkan pola yang tidak relevan pada pelatihannya (mengalami gangguan/*noise*) terhadap data baru yang belum pernah dilihat sebelumnya. Hasil dari evaluasi *loss function* untuk akurasi hasil *output* optimalisasi juga menunjukkan nilai *loss* sebesar 0,0033, MAE sebesar 0,0446 ≤ 0,1 (sangat akurat), RMSE sebesar 0,0572 ≤ 0,1 (sangat baik), dan R^2 sebesar 0,9 ≤ 0,9349 < 1 (kuat). Adapun untuk grafik SF aktual vs prediksi, garis prediksi model ANN dengan pemrograman Python (SF 1.6638 dengan sudut kemiringan 50 derajat) sangat mendekati SF aktual yang dimana berada pada SF 1.659 pada sudut kemiringan 50 derajat. Sehingga, dapat dikatakan bahwa nilai keamanan lereng (SF) pada *inter-ramp* 2 (tengah) ini teroptimalisasi dengan baik oleh model ANN. Akan tetapi, data *input layer* berdasarkan sudut kemiringan lereng yang divariasikan ini hanya sampai pada sudut 50 derajat karena mengacu pada pesyaratan dan kajian tim *geotechnical engineering* yang digunakan di proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi. Sehingga, penelitian ini tidak dapat melihat optimalisasi secara lebih luas yang lebih mendekati SF target yang disyaratkan (SF 1.25), sehingga lereng mungkin masih bisa aman jika digunakan sudut kemiringan (α) > 50 derajat untuk *inter-ramp* tengah ini.

Adapun untuk *output* yang didapatkan berupa model terbaik untuk *inter-ramp* tengah dapat dilihat seperti pada Gambar 5.17 dan Gambar 5.18 di bawah ini.



Gambar 5.17 Hasil Prediksi ANN Terhadap Optimalisasi Nilai Keamanan Lereng (SF) pada *Inter-Ramp* Tengah

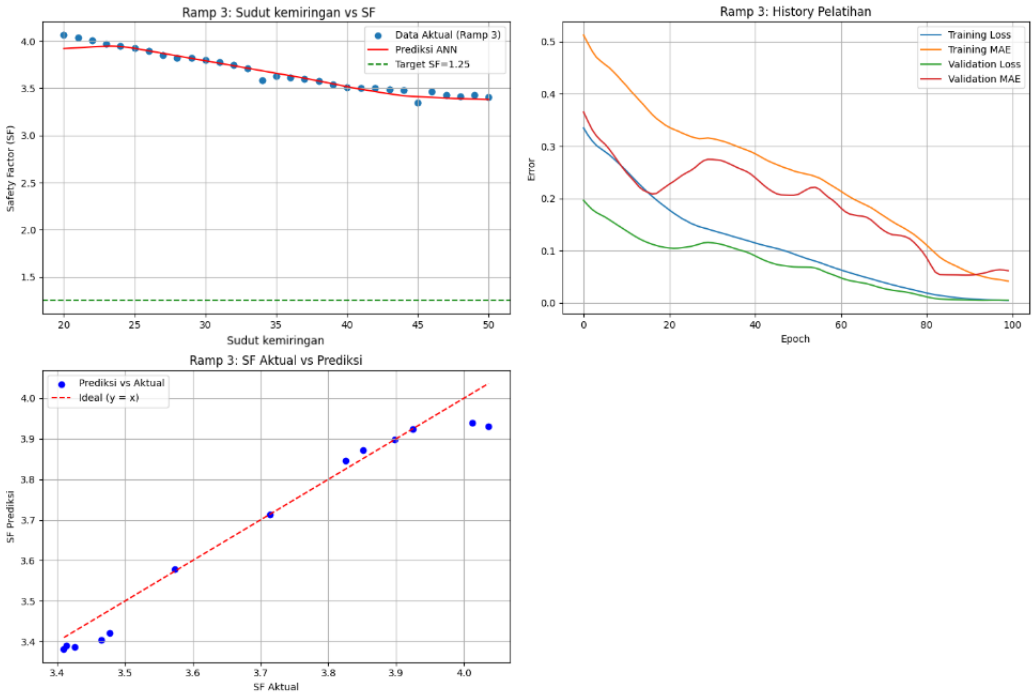
```
Ramp 2:
  a optimal      = 50.00
  Prediksi SF    = 1.6638
  Hasil Evaluasi Test Set:
    loss: 0.0033
    mae: 0.0446
    rmse: 0.0572
    r_squared: 0.9349
```

Gambar 5.18 Akurasi Hasil Model ANN pada *Inter-Ramp* Tengah

3. Hasil Model Terbaik *Inter-Ramp* Bawah

   Dari Gambar 5.19 dan Gambar 5.20 di bawah, nilai keamanan lereng (SF) pada *inter-ramp* 3 (bawah) menunjukkan nilai prediksi 3,3820 yang mendekati SF yang ditargetkan atau di syarat kan (SF 1.25) dengan kemiringan lereng (α) yang aman berada pada kemiringan 50 derajat. *History* pelatihan pada *inter-ramp* 3 menunjukkan konsistensi garis linear yang mengalami pola penurunan yang sedikit tidak relevan (*noice*), akan tetapi

setelahnya cenderung menurun dengan baik yang menunjukkan bahwa model sedikit mengalami *overfitting* dari pelatihannya akan tetapi masih dapat dipertimbangkan. *Overfitting* menunjukkan pola yang tidak relevan pada pelatihannya (mengalami gangguan/*noise*) terhadap data baru yang belum pernah dilihat sebelumnya. Hasil dari evaluasi *loss function* untuk akurasi hasil *output* optimalisasi juga menunjukkan nilai *loss* sebesar 0,0041, MAE sebesar 0,0465 ≤ 0,1 (sangat akurat), RMSE sebesar 0,0637 ≤ 0,1 (sangat baik), dan R^2 sebesar 0,9 ≤ 0,9614 < 1 (kuat). Adapun untuk grafik SF aktual vs prediksi, garis prediksi kombinasi ANN dan Python (SF 3,3820 dengan sudut kemiringan 50 derajat) sangat mendekati SF aktual yang dimana berada pada SF 3.410 pada sudut kemiringan 50 derajat. Sehingga, dapat dikatakan bahwa nilai keamanan lereng (SF) pada *inter-ramp* 3 (bawah) ini teroptimalisasi dengan baik oleh model ANN. Akan tetapi, data *input layer* berdasarkan sudut kemiringan lereng yang divariasikan ini hanya sampai pada sudut 50 derajat karena mengacu pada pesyaratan dan kajian tim *geotechnical engineering* yang digunakan di proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi. Sehingga, penelitian ini tidak dapat melihat optimalisasi secara lebih luas yang lebih mendekati SF target yang disyaratkan (SF 1.25), sehingga lereng mungkin masih bisa aman jika digunakan sudut kemiringan (α) > 50 derajat untuk *inter-ramp* bawah ini. Adapun untuk *output* yang didapatkan berupa model terbaik untuk *inter-ramp* bawah dapat dilihat seperti pada Gambar 5.19 dan Gambar 5.20 di bawah ini.



Gambar 5.19 Hasil Prediksi ANN Terhadap Optimalisasi Nilai Keamanan Lereng (SF) pada *Inter-Ramp* Bawah

```
Ramp 3:
  a optimal      = 50.00
  Prediksi SF    = 3.3820
  Hasil Evaluasi Test Set:
    loss: 0.0041
    mae: 0.0465
    rmse: 0.0637
    r_squared: 0.9614
```

Gambar 5.20 Akurasi Hasil Model ANN pada *Inter-Ramp* Bawah

Rekapitulasi kemiringan lereng (α) dan SF hasil dari optimalisasi model ANN vs analisis GeoStudio beserta akurasi hasil model ANN dari tiap masing-masing *inter-ramp* pada lereng tinjauan penelitian di proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi dapat dilihat pada Tabel 5.3 dan Tabel 5.4 di bawah ini. Kemudian untuk rekapitulasi arsitektural ANN yang digunakan dalam membuat model ANN dapat dilihat pada Tabel 5.5 sebagai berikut.

Tabel 5.3 Rekapitulasi Hasil dari Optimalisasi Model ANN vs Analisis GeoStudio

Batas Jenjang	Sudut Kemiringan (°)		SF		Selisih SF
	ANN	GeoStudio	ANN	GeoStudio	
Inter-Ramp 1 (Atas)	46,06	46	1.25	1.256	0.0060
Inter-Ramp 2 (Tengah)	50	50	1.6638	1.659	0.0048
Inter-Ramp 3 (Bawah)	50	50	3.3820	3.410	0.0280

Tabel 5.4 Rekapitulasi Akurasi Hasil Model ANN

Model ANN	Loss	RMSE	R^2	MAPE
		(≤ 0,1)	(0,9 ≤ R^2 ≤ 1)	(≤ 0,1)
Inter-ramp 1 (Atas)	0,0008	0,0285	0,9879	0,0254
Inter-ramp 2 (Tengah)	0,0033	0,0572	0,9349	0,0446
Inter-ramp 3 (Bawah)	0,0041	0,0637	0,9614	0,0465

Tabel 5.5 Rekapitulasi Arsitektural ANN

Arsitektur ANN	Jumlah	Keterangan
Input Layer	1	7 parameter data input
Hidden Layers	3	30, 20, 10 neuron
Output Layer	1	Nilai keamanan lereng optimal dengan sudut kemiringan yang aman
Hyperparameter	1	ReLU
Optimizer	1	Adam
Jaringan Saraf	1	MLP/Backpropagation (BP)
Pembagian Data	2	80% pelatihan dan 20% pengujian secara random
Epochs	100	Model melewati 1x proses pelatihan ANN
Loss Function	3	RMSE, R^2, MAPE

BAB VI
KESIMPULAN DAN SARAN

6.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, yang diawali dari tahap studi literatur, pengumpulan data, *input* data-data parameter geoteknik, membuat model lereng dengan banyak variasi sudut kemiringan lereng (α), analisis model menggunakan *Slope/W* dengan metode *Fellenius* untuk mendapatkan nilai keamanan lereng (SF) aktual, pengembangan model ANN, pelatihan dan pengujian model ANN, hingga didapatkan hasil model terbaik untuk optimalisasi nilai keamanan lereng (SF) pada semua *inter-ramp* di proyek pertambangan PT Cipta Kridatama di Dusun Tanjung Belit, Provinsi Jambi ini, maka dirumuskan dan diperoleh bebarapa kesimpulan antara lain sebagai berikut.

1. Hasil Nilai Keamanan Lereng (SF) Melalui Analisis *Software* Stabilisasi Lereng Sebagai Data Aktual

   Hasil dari analisis menunjukkan bahwa nilai keamanan lereng (SF) yang mencapai target syarat yang digunakan (SF 1.25) berada pada *range* sudut kemiringan lereng (α) 20 – 47 derajat.

2. Arsitektural *Artificial Neural Network* (ANN) Terhadap Nilai Keamanan Lereng (SF) yang Optimal Apabila digunakan Variabel Optimalisasi Model

   Penelitian ini mengembangkan model ANN yang dibantu dengan bahasa pemrograman Python melalui Visual Studio Code sebagai *platform*, dengan *environment*/*requirements* yang digunakan yakni Anaconda versi 24.9.2 dan Python *Interpreter* 3.10.11. Arsitektur ANN pada pemodelan ini memiliki 1 lapisan masukan (*input layer*) yang di dalamnya terdapat 7 parameter data himpunan dimana berisikan variabel-variabel bebas yakni nilai kohesi tanah (c), sudut geser dalam (φ), berat volume tanah (γ), ketinggian lereng (H), muka air tanah (MAT), dan beban merata (q), serta variabel terikat yakni

sudut kemiringan lereng (α) dan nilai keamanan lereng (SF), kemudian 3 lapisan tersembunyi (*hidden layers*) dimana memiliki 30, 20, dan 10 neuron dengan fungsi aktivasi ReLU. Selanjutnya juga terdapat 1 lapisan keluaran (*output layer*) yang memiliki 1 neuron sesuai dengan tujuannya untuk regresi. Adapun *output* yang ingin dihasilkan adalah nilai keamanan lereng (SF) optimal yang mendekati atau sama dengan SF 1.25 dengan *optimize*.

3. Akurasi Penggunaan ANN Terhadap Nilai Keamanan Lereng (SF) yang Optimal

   Hasil akurasi penggunaan ANN pada *inter-ramp* 1 (atas) menunjukkan akurasi yang baik untuk optimalisasi nilai keamanan lereng (SF) yang digunakan sebesar 1.25 pada sudut kemiringan 46,06 derajat. Meskipun pada *inter-ramp* tengah dan bawah SF yang dihasilkan (1.6638 dan 3.3820) lebih tinggi 1.25, akan tetapi ketiga model ANN tetap menunjukkan akurasi kinerja yang kuat dan andal terbukti dengan nilai R^2 yang dikeluarkan berada di antara 93,5% – 98,8% serta nilai RMSE dan MAPE di bawah dari 10%.

Sehingga dari beberapa kesimpulan tersebut, didapatkan kesimpulan secara garis besar bahwa dengan mendapatkan kemiringan lereng (α) yang aman dengan nilai keamanan lereng (SF) yang optimal, penelitian ini dapat menjadi pertimbangan atau rekomendasi untuk perencanaan pembukaan tambang di masa depan, mengurangi volume galian yang terlalu banyak, ataupun mendukung praktik pertambangan yang lebih bertanggung jawab dan berkelanjutan untuk pengambilan keputusan yang tepat terkait pengendalian risiko dan keselamatan kerja di lokasi pertambangan.

6.2 Saran

Beberapa saran akan disampaikan pada penelitian ini yang diharapkan dapat menjadi pertimbangan untuk penelitian yang akan datang atau selanjutnya. Saran-saran ini didasari oleh temuan yang dipikirkan dan diperoleh selama penelitian atau

proses pengolahan data dengan tujuan untuk meningkatkan kualitas dan hasil penelitian yang mungkin relevan. Adapun saran-saran tersebut di antaranya yaitu sebagai berikut.

1. Perlu diterapkannya uji coba atau eksperimen di lapangan untuk memvalidasi hasil prediksi optimalisasi nilai keamanan lereng (SF) dari model terbaik yang didapatkan. Model ANN yang dikembangkan dalam penelitian ini adalah berdasarkan dari kajian-kajian studi literatur terhadap data-data parameter lapangan yang digunakan. Oleh karena itu, uji coba atau eksperimen di lapangan sangat penting untuk dilakukan agar memastikan model ternyata benar dan akurat untuk digunakan di dalam kehidupan atau lapangan yang membuktikan apakah tidak terjadi suatu kesalahan fatal dalam hasil analisis atau prediksi.
2. Lakukan penelitian lanjutan dengan memperbanyak *dataset* dengan studi kasus tambahan pada lereng-lereng pertambangan yang sama atau berbeda lebih banyak lagi untuk memverifikasi konsistensi dan keandalan model ANN dalam berbagai kondisi geoteknik yang berbeda, serta memperluas variasi model dengan sudut kemiringan lereng (α) di atas 50 derajat terutama untuk *inter-ramp* tengah dan bawah untuk membandingkan dan menunjukkan berapa sudut kemiringan lereng (α) yang aman dengan nilai SF sejauh mana mendekati target optimal yang disyaratkan (SF 1.25). Hal ini tentu memungkinkan ANN menganalisis dan mengidentifikasi sudut yang lebih curam namun tetap aman untuk mengurangi volume galian secara signifikan, meskipun harus dengan pertimbangan tim *geotechnical engineering* lagi untuk dapat digunakan atau tidak realisasinya di lapangan.
3. Model ANN yang dikembangkan di dalam penelitian ini hanya mempertimbangkan variabel terikatnya dari rumus nilai keamanan lereng (SF) secara umum atau dari metode *Fellenius*, yakni salah satunya adalah sudut kemiringan lereng (α), sehingga data-data parameter lainnya seperti nilai kohesi, gamma, sudut geser dalam, muka air tanah, ketinggian lereng,

dan lainnya pada realisasinya dapat berubah sewaktu-waktu pada setiap lapisannya karena faktor-faktor yang bisa saja mempengaruhinya seperti hujan, perubahan sifat material karena pelapukan jangka panjang, dan lainnya. Oleh karena itu, penelitian ini dapat menjadi penelitian lanjutan jangka panjang, dimana ANN yang digunakan dalam penelitian ini dapat menjadi dasar dari optimalisasi nilai keamanan lereng (α) yang telah dilatih seberapa baiknya ANN dalam memprediksi hasil berdasarkan sudut kemiringan lereng (α) dalam menghasilkan SF yang optimal dari lokasi lereng yang ditinjau. Untuk itu, mungkin perlu adanya penyempurnaan model atau optimasi model dengan beberapa parameter lainnya yang divariasikan agar dapat menjadi model acuan atau ketetapan. Jadi, nantinya dengan menggunakan *dataset* apapun, model dapat langsung mengacu pada data *training* nya yang memuat beberapa parameter tersebut.

4. Penelitian ini menggunakan pemodelan *Artificial Neural Network* (ANN) yang dibantu dengan bahasa pemrograman Python. Penelitian lainnya yang dapat dilakukan dengan mencoba model lainnya, seperti *Convolutional Neural Network* (CNN), *Recurrent Neural Network* (RNN), *Random Forest*, *Support Vector Machines* (SVM), *Naive Bayes*, *K-Nearest Neighbors* (KNN), *LightGBM*, *Arima/Sarima*, *Ensemble Learning*, dan lainnya untuk membandingkan hasil prediksi dan keakuratan *output* dalam menemukan model yang paling maksimal atau optimal.
5. Jika memungkinkan, integrasikan data historis kejadian longsor atau pergerakan lereng yang pernah terjadi pada lokasi tinjauan lereng penelitian, serta data-data *real-time* dari sensor pemantauan lereng (misalnya inclinometer, piezometer, patok, EWS, ekstensometer, radar SSR, ataupun sensor lainnya), untuk melatih dan memvalidasi model menjadi lebih baik dan berpengetahuan. Sehingga, data-data *real-time* tersebut dapat meningkatkan kemampuan adaptif model ANN untuk memprediksi perubahan kondisi lereng secara dinamis, yang memungkinkan adanya pengembangan sistem peringatan dini yang efektif.

DAFTAR PUSTAKA

Adhi, A.B. (2009). Implementasi Permodelan Artificial Neural Network (ANN) dalam Prediksi Date Time Series Penjualan Studi Kasus PT. Varia Usaha Beton. Tugas Akhir. Institut Teknologi Sepuluh Nopember. Surabaya.

Afifuddin, M., Nafira, D. dan Fachrurrazi. (2021). Prediksi Kuat Tekan Beton Kinerja Tinggi dengan Pemodelan Metode Artificial Neural Network (ANN). Jurnal Teknik Sipil. Vol. 10, No. 2: 1-15.

Alfis, S. (2013). Jaringan Syaraf Tiruan untuk Memprediksi Laju Pertumbuhan Penduduk. *Jurnal Teknologi Informasi (JUTI)*, *11*(1), 37-44.

Chollet, F. (2021). Deep Learning with Python. Edisi ke-2. Shelter Island, *NY: Manning Publications*.

Das, Bradja M. dan Endah Noor. (1994). Mekanika Tanah (Prinsip-Prinsip Rekayasa Geoteknis). Jilid 2. Penerbit Erlangga, Jakarta.

Dokumen Kuansing Inti Makmur: KIM-MED-POS-002-R02-Pembuatan Design PIT.

Dokumen Kuansing Inti Makmur: KIM-MED-PPO-021-R01-Pembuatan Geotechnical Memorandum.

Dokumen Kuansing Inti Makmur: KIM-MED-PPO-020-R01-Pemantauan Lereng Tambang.

Fausett, L. (1994). Fundamentals of Neural Networks: Architectures, Algorithms, and Applications. Prentice-Hall.

Firdaus, Y., Sarie, F. dan Hendri, O. (April 2022). Analisis Stabilitas Lereng Menggunakan Metode Fellenius Studi Kasus: Proyek Pekerjaan Drainase Gedung PPIIG di Universitas Palangka Raya. *Jurnal Teknika: Universitas Palangka Raya*. Vol. 5, No. 2.

Gao, Wei. (4 Januari 2019). A Predictive Model Based on an Optimized ANN Combined with ICA for Predicting the Stability of Slopes. DOI: https://doi.org/10.1007/s00366-019-00702-7. E-mail: gaowei@ynnu.edu.cn.

Hagan, M., Demuth, H., dan Beale, M. (2002). Neural Network Design. Campus Pub Service. University of Colorado Bookstore.

Hardiyatmo, H. C. (2002). Mekanika Tanah II (3rd uppl.). Penerbit Gadjah Mada University Press, Yogyakarta.

Hardiyatmo, H.C. (Oktober 2008). Geosintetik untuk Rekayasa Jalan Raya Perancangan dan Aplikasi. *Yogyakarta: Gadjah Mada University Press*. ISBN 979-420-688-1. E-mail: gmupress@ugm.ac.id. http://www.gmup.ugm.ac.id.

Hardiyatmo, H.C. (Oktober 2010). Mekanika Tanah 2 Edisi Kelima. *Universitas Gadjah Mada Yogyakarta: Jurusan Teknik Sipil dan Lingkungan*. ISBN 979-420-736-5. E-mail: gmupress@ugm.ac.id. http://www.gmup.ugm.ac.id.

Haykin. S. (2009). Neural Networks and Learning Machines. *United State of America: Pearson*.

Hibatulloh, Ilyas M. (Oktober 2024). Optimasi Proporsi Bahan Subtitusi Dalam Campuran Beton Terhadap Kuat Tekan Menggunakan Metode Artificial Neural Network. *Universitas Islam Indonesia: Program Studi Teknik Sipil Fakultas Teknik Sipil dan Perencanaan*. Available: https://dspace.uii.ac.id.

Jing, Yangfan (2025). Factor of Safety Prediction for Slope Stability Using PCA and BPNN in Guangdong's H Mining Area. Available: www.nature.com/scientificreports/. DOI: https://doi.org/100.1038/s41598-025-95498-6.

Kajian-Kajian Tim Geotechnical Engineering PT Cipta Kridatama, Site Jambi.

Keputusan Menteri ESDM Nomor 1827 K/30/MEM/2018 tentang Pedoman Pelaksanaan Kaidah Teknik Pertambangan yang Baik.

Kingma, D. P., & Ba, J. (2015). Adam: A method for stochastic optimization. *Prosiding Konferensi Internasional ke-3 tentang Representasi Pembelajaran (ICLR)*. Available: https://arxiv.org/abs/1412.6980.

Kusumadewi, S. (2012). Membangun Jaringan Syaraf Tiruan Menggunakan MATLAB dan Excel Link. Graha Ilmu. Yogyakarta.

Lewis, C. D. (1982). *Industrial and Business Forecasting Methods: A Practical Guide to Exponential Smoothing and Curve Fitting*. Butterworth-Heinemann.

Maji'aturrohmah. (Maret 2024). Optimalisasi Beton Prategang PCI Girder pada Jembatan Perning Kloji, Mojokerto Menggunakan Metode Artificial Neural Network. *Universitas Islam Indonesia: Program Studi Teknik Sipil Fakultas Teknik Sipil dan Perencanaan.* Available: https://dspace.uii.ac.id.

Margaretha, V. G. dan Sompie, O.B.A. (Januari 2014). Analisis Kestabilan Lereng dengan Metode Fellenius (Studi Kasus: Kawasan Citraland). *Fakultas Teknik, Jurusan Teknik Sipil: Universitas Sam Ratulangi Manado*. Jurnal Sipil Statik Volume 2 Nomor 1, Januari 2014 (37-46) ISSN: 2337-6732.

Moore, D.S., Notz, W.I., dan Finger, M.A. (2013). The Basic Practice of Statistics, 6 th ed. W.H. Freeman and Company. New York, NY.

Nugroho, Y. S. dan Hargiono, S. (2021). Analisis Stabilitas Lereng pada Area Penambangan Batugamping di PT. Semen Gresik Pabrik Rembang. *Jurnal Bina Tambang*. Vol. 6, No. 4, 1-10.

Pedoman Konstruksi dan Bangunan. (2024). Rekayasa Penanganan Keruntuhan Lereng pada Tanah Residual dan Batuan. Pd T-09-2005-B.

Prathama, A. A., Wiguna, I. P. A., dan Hidayati, A. M. (2021). Estimasi Biaya Proyek Konstruksi Menggunakan Artificial Neural Network (ANN) dengan Variabel Input yang Signifikan. *Jurnal Mahasiswa Teknik Sipil*.

Rada, Y.H.M., dan Aji, P. (2019). Prediksi Kekuatan Beton Berdasarkan Parameter Design, Hammer Test dan Test UPV Dengan Menggunakan Artificial Neural Network (ANN). *Journal of Civil Engineering*. Vol. 34, No. 1, Mei: 45-60.

Ridlo, M. R., Hardawati, A., Jamal, A. U., dan Suharyatma. (2023). Penggunaan Artificial Neural Network (ANN) untuk Memprediksi Nilai Demand Capacity Ratio (DCR) pada Struktur Atas Jembatan Rangka Bina Marga Kelas A Bentang 45 Meter. *Proceeding Civil Engineering Research Forum*. Vol. 3, No. 1, Juli: 31.

Sari, S.N., Pratama, B.G., dan Prastowo, R. (2024). *Artificial Neural Network: Identifikasi Bangunan Daerah Rawan Longsor*. Penerbit Adab. Jakarta.

Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, *2* (160). https://doi.org/10.1007/s42979-021-00592-x.

Sarno, R., Navastara, D. A. dan Fatichah, C. (2021). Pemrograman Deep Learning Menggunakan Python. ITS Press.

Sembiring, M.A. (2024). Analisis Faktor Prediksi Diagnosa Tingkat Serangan Jantung Menggunakan Metode Regression. Jurnal Teknisi (Jurnal Teknologi Komputer dan Sistem Informasi). Vol. 4 No. 1:16-22.

Siang, J.J. (2004). Jaringan Syaraf Tiruan dan Pemrogramannya menggunakan MATLAB. Penerbit Andi. Yogyakarta.

Syafiq, Alhalim. (Juli 2024). Penerapan Artificial Neural Network Sebagai Upaya Optimalisasi Struktur Kolom pada Proyek Perluasan Lombok Epicentrum Mall dan Podium Parkir. *Universitas Islam Indonesia: Program Studi Teknik Sipil Fakultas Teknik Sipil dan Perencanaan*. Available: https://dspace.uii.ac.id.

Terzaghi, K. (1950). Theoritical Soil Mechanics. John Wiley & Sons, New York.

Wang, Ze-Zhou & Goh, S. H. (2021). Novel Approach to Efficient Slope Reliability Analysis in Spatially Variable Soils. Engineering Geology 281 (2021) 105989. *Singapore: Departement of Civil & Environmental Engineering, National University of Singapore*. Available: ScienceDirect. www.elsevier.com/locate/enggeo. DOI: https://doi.org/10.1016/j.enggeo.2020.105989.

Xu Haoding. (2023). Machine Learning in the Stochastic Analysis of Slope Stability: A State-of-the-Art Review. Modelling 2023, 4, 426-453. DOI: https://doi.org/10.3390/modelling4040025.