

url : <http://studentjournal.umpo.ac.id/index.php/komputek>

---

## Pengaruh Struktur Hidden Layer pada Model Multilayer Perceptron terhadap Prediksi Status Akademik Mahasiswa

Emir Syarif Machfudz<sup>1</sup>, Farhansyah Putra<sup>2</sup>, Khairuman Alfi<sup>3</sup>, Armansyah<sup>4</sup>

Program Studi Ilmu Komputer, Fakultas Sains dan Teknologi,  
Universitas Islam Negeri Sumatera Utara

E-mail Korespondensi : <sup>1)</sup>[emirsyarifm@gmail.com](mailto:emirsyarifm@gmail.com), <sup>2)</sup>[farhansyahputra0212@gmail.com](mailto:farhansyahputra0212@gmail.com), <sup>3)</sup>[khairumanalfi@gmail.com](mailto:khairumanalfi@gmail.com),  
<sup>4)</sup>[armansyah@uinsu.ac.id](mailto:armansyah@uinsu.ac.id)

History Artikel

Diterima : 26 November 2024

Disetujui : 19 Februari 2025

Dipublikasikan : 26 April 2025

---

### **Abstract**

*The phenomenon of students at risk of dropout is an important concern for higher education institutions because it impacts the quality and accreditation of the institution. This research aims to utilize an artificial neural network (ANN) with Multilayer Perceptron (MLP) architecture to predict student academic status based on historical data. The analysis focuses on the effect of the number of hidden layers on the performance of the model, by comparing the configuration of 3 hidden layers and 4 hidden layers. The dataset used contains 1,337 student data, including features such as year of entry, length of study, GPA, total credits, and tuition fees. The data is processed through MinMaxScaler normalization and processed using Scikit-learn with ReLU activation function, Adam optimizer, and Log Loss loss function. Results show that the 3 hidden layer configuration produces the highest accuracy of 95.52% with a faster training time than the 4 hidden layer configuration which only achieves 94.03% accuracy. This finding shows that the optimal number of hidden layers can improve model performance while maintaining computational efficiency. The developed model has the potential to assist educational institutions in preventing dropout through early detection and targeted intervention.*

**Keywords:** Artificial Neural Network, Multilayer Perceptron, Hidden Layer, Dropout Prediction, Student Academic Status

## **Abstrak**

Fenomena mahasiswa yang berisiko dropout menjadi perhatian penting bagi institusi pendidikan tinggi karena berdampak pada kualitas dan akreditasi lembaga. Penelitian ini bertujuan memanfaatkan jaringan syaraf tiruan (JST) dengan arsitektur Multilayer Perceptron (MLP) untuk memprediksi status akademik mahasiswa berdasarkan data historis. Analisis difokuskan pada pengaruh jumlah hidden layer terhadap kinerja model, dengan membandingkan konfigurasi 3 hidden layer dan 4 hidden layer. Dataset yang digunakan berisi 1.337 data mahasiswa, mencakup fitur seperti tahun masuk, lama studi, IPK, total SKS, dan biaya kuliah. Data diproses melalui normalisasi MinMaxScaler dan diolah menggunakan Scikit-learn dengan fungsi aktivasi ReLU, optimizer Adam, dan fungsi loss Log Loss. Hasil menunjukkan bahwa konfigurasi 3 hidden layer menghasilkan akurasi tertinggi sebesar 95,52% dengan waktu pelatihan yang lebih cepat dibandingkan konfigurasi 4 hidden layer yang hanya mencapai akurasi 94,03%. Temuan ini menunjukkan bahwa jumlah hidden layer yang optimal dapat meningkatkan performa model sekaligus menjaga efisiensi komputasi. Model yang dikembangkan memiliki potensi untuk membantu institusi pendidikan dalam mencegah dropout melalui deteksi dini dan intervensi yang tepat sasaran.

**Kata Kunci:** Jaringan Syaraf Tiruan, Multilayer Perceptron, Hidden Layer, Prediksi Dropout, Status Akademik Mahasiswa

**How to Cite:** Emir Syarif Machfudz (2025). Pengaruh Struktur Hidden Layer pada Model Multilayer Perceptron terhadap Prediksi Status Akademik Mahasiswa. KOMPUTEK : Jurnal Teknik Universitas Muhammadiyah Ponorogo, Vol 9 (1): Halaman 9-21

© 2025 Universitas Muhammadiyah Ponorogo. All rights reserved

---

ISSN 2614-0985 (Print)  
ISSN 2614-0977 (Online)

## PENDAHULUAN

Jaringan syaraf tiruan dapat digunakan untuk mengenali pola sebagai salah satu bentuk kecerdasan buatan yang memanfaatkan teknologi komputasi (Rivan & Sung, 2021)(Maiyuriska, 2022). Pola yang diklasifikasi dalam sebuah model Multilayer Perceptron akan menghasilkan prediksi yang akurat. Namun dalam eksperimen ditemukan perbedaan akurasi maupun waktu berapa lama suatu pola dalam sebuah model dilatih. Banyak ditemukan penelitian yang berbeda dalam segi akurasi walaupun dengan pola yang sama. Untuk mencapai akurasi yang tinggi banyak variabel penentu apakah model tersebut akurasinya akan tinggi atau biasa saja. Dalam penelitian ini, hidden layer sebagai objek yang akan diteliti untuk menghasilkan akurasi yang tinggi.

Hidden layer pada dasarnya adalah lapisan perantara antara input layer (lapisan masukan) dan output layer (lapisan keluaran) dalam jaringan saraf. Jumlah hidden layer dalam jaringan berubah sesuai dengan jenis masalah yang dihadapi. Beberapa masalah hanya membutuhkan satu hidden layer, sementara yang lain membutuhkan beberapa hidden layer. Hidden layer terdiri dari kumpulan neuron kecil yang berfungsi untuk mentransfer data dan informasi pelatihan dari satu lapisan ke lapisan lainnya (Uzair & Jamil, 2020).

Penelitian ini dilakukan untuk menganalisis pengaruh lapisan tersembunyi dalam sebuah arsitektur model yang memprediksi mahasiswa yang terancam dropout dengan menggunakan model klasifikasi berupa algoritma MLP (Multilayer Perceptron).

Multilayer Perceptron (MLP) terdiri dari sejumlah besar prosesor saraf terdistribusi yang saling terhubung. Komponen dinamis non-linear dalam prosesor ini memperluas data input

menjadi kombinasi linear sinapsis. Namun, kemampuan pemetaan non-linear dari MLP konvensional memiliki keterbatasan ketika memproses informasi dengan tingkat kompleksitas yang tinggi (Ren, Su, Yang, Lau, & Liu, 2022).

Dengan menggunakan MLP, model diharapkan dapat memprediksi mahasiswa yang terancam dropout dengan akurat. Namun pada model ini diteliti apa perbedaan jumlah lapisan tersembunyi dan bagaimana pengaruh model klasifikasi ini dapat meningkatkan akurasi prediksi. Dalam kasus ini digunakan library scikit-learn untuk memudahkan peneliti agar fokus pada hidden layer saja.

Scikit-learn adalah library Python yang menyediakan antarmuka standar untuk mengimplementasikan algoritma pembelajaran mesin. Library ini juga mencakup berbagai fungsi tambahan yang menjadi bagian penting dari proses pembelajaran mesin, seperti langkah-langkah prapemrosesan data, teknik resampling data, parameter evaluasi, dan antarmuka pencarian untuk menyesuaikan atau mengoptimalkan kinerja suatu algoritma (Bisong, 2019).

Modifikasi hidden layer dilakukan agar diketahui jumlah hidden layer mana yang paling bagus dalam mencari akurasi prediksi pada data mahasiswa yang terancam dropout. Maka dari itu penelitian ini bertujuan untuk meneliti klasifikasi data mahasiswa yang terancam dropout dengan mengetahui perbandingan 2 jenis hidden layer dari model multilayer perceptron yaitu 3 hidden layer dan 4 hidden layer. Penelitian ini difokuskan untuk mencari jumlah hidden layer yang paling baik dalam mengklasifikasi mahasiswa.

Dalam penelitian serupa, dataset yang kecil sudah cukup tidak menggunakan hidden layer pada model klasifikasinya untuk mendapatkan akurasi yang tinggi. Tetapi untuk dataset yang besar dibutuhkan penambahan hidden layer agar akurasi meningkat. Berdasarkan pengamatan pada penelitian terdahulu mengenai jaringan saraf, ditemukan bahwa pengurangan jumlah lapisan tersembunyi memiliki dampak langsung pada akurasi jaringan. Pada masalah yang kompleks, jumlah lapisan tersembunyi yang terlalu sedikit dapat menyebabkan jaringan tidak terlatih dengan baik. Sebaliknya, ketika jumlah lapisan tersembunyi melebihi jumlah optimal (tiga lapisan), kompleksitas waktu meningkat secara signifikan dibandingkan dengan peningkatan akurasi yang diperoleh (Uzair & Jamil, 2020).

Oleh karena itu penelitian ini diharapkan untuk menerapkan apakah teori pada penelitian yang serupa bisa digunakan untuk mengetahui jumlah hidden layer terbaik untuk menentukan klasifikasi mahasiswa yang terancam dropout. Dengan ini peneliti selanjutnya dapat menentukan jumlah hidden layer yang tepat agar mencapai akurasi yang diinginkan.

## **METODE PENELITIAN**

Penelitian ini bertujuan untuk menganalisis pengaruh jumlah hidden layer pada model klasifikasi algoritma Multilayer Perceptron (MLP) dalam memprediksi mahasiswa yang berpotensi dropout. Penelitian dilakukan berdasarkan

pendekatan kuantitatif dengan menggunakan data historis mahasiswa.

## **Rancangan Penelitian**

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimen. Penelitian dilakukan untuk menguji performa model MLP dengan 3 hidden layer dan 4 terhadap akurasi maupun presisi, recall, dan waktu komputasi.

Populasi penelitian adalah data mahasiswa dari sebuah universitas berdasarkan stambuk yaitu stambuk 2015-2021. Sampel penelitian terdiri dari 1.337 data mahasiswa yang dipilih menggunakan metode sampling berdasarkan kriteria:

- a. Memiliki riwayat akademik lengkap (tahun masuk, lama studi, indeks prestasi semester, indeks prestasi kumulatif, sks semester, total sks, serta biaya kuliah).
- b. Berstatus aktif, lulus, potensi lulus, potensi dropout, dropout.

Variabel input dari penelitian ini adalah Fitur-fitur seperti tahun masuk, lama studi, indeks prestasi semester, indeks prestasi kumulatif, sks semester, total sks, serta biaya kuliah. Sedangkan untuk variabel target adalah label status mahasiswa yaitu, 0: aktif, 1: lulus, 2: potensi lulus, 3: potensi dropout, 4: dropout.

## **Prosedur Penelitian**

Adapun prosedur yang dilakukan dalam penelitian adalah sebagai berikut.



**Gambar 1.** Alur Prosedur Penelitian

### 1. Pengumpulan Data

Data diperoleh dari sistem informasi akademik universitas dengan izin resmi. Data dikategorikan menjadi fitur input yaitu independent variable dan target output adalah dependent variable.

### 2. Prapemrosesan Data


Tahap prapemrosesan data dilakukan untuk memastikan kualitas data yang optimal sebelum digunakan dalam pengembangan model. Langkah pertama adalah membersihkan data dari nilai yang hilang (missing values), karena keberadaan nilai yang hilang dapat mengurangi akurasi model dan memengaruhi interpretasi hasil.

Data yang hilang diatasi dengan pendekatan seperti penghapusan atau imputasi, tergantung pada tingkat dan distribusi nilai yang hilang. Setelah itu, data dinormalisasi menggunakan metode

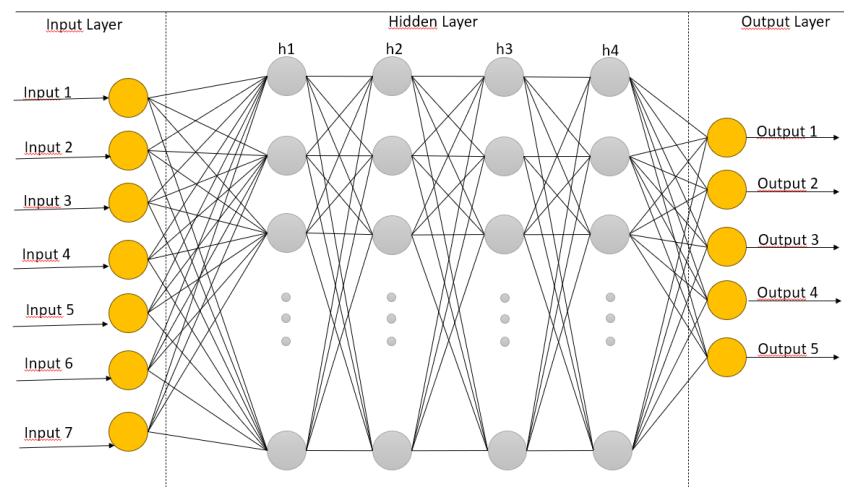
MinMaxScaler untuk mengubah nilai-nilai fitur menjadi rentang tertentu, biasanya antara 0 dan 1. Proses normalisasi ini bertujuan untuk menyamakan skala fitur-fitur yang berbeda, sehingga algoritma pembelajaran dapat berjalan lebih efektif dan menghindari dominasi fitur dengan skala besar. Kombinasi kedua langkah ini memastikan bahwa data yang digunakan siap untuk menghasilkan model yang andal dan akurat.

### 3. Pembangunan Arsitektur Model MLP

Model MLP dibangun menggunakan library Scikit-learn. Pada penelitian ini digunakan 3 dan 4 layer, dengan jumlah neuron yang sama di setiap layer.



**Gambar 2.** Arsitektur 3 Hidden Layer



**Gambar 3.** Arsitektur 4 Hidden Layer

Fungsi aktivasi yang digunakan adalah ReLU (Rectified Linear Unit). Fungsi aktivasi ReLU banyak digunakan oleh peneliti deep learning karena efisiensi komputasinya, kemudahan implementasinya, sifatnya yang intuitif, dan lain sebagainya (Hasan, Hossain, Srizon, & Sayeed, 2023).

Keluaran atau output layer menggunakan Fungsi aktivasi logistic sigmoid untuk klasifikasi biner. Fungsi aktivasi logistic sigmoid digunakan untuk melatih data eksperimen pada model jaringan saraf tiruan atau Artificial Neural Network yang disingkat ANN (Dharmalingam et al., 2023).

Adam yang secara otomatis dikelola oleh Scikit-learn adalah optimizer yang dipakai. Algoritma Adaptive Moment Estimation (Adam) yang diusulkan dalam beberapa tahun terakhir telah banyak digunakan dalam penelitian Artificial Intelligence dan merupakan alat yang kuat

untuk menyelesaikan masalah (Zheng, Wang, Chen, & Meng, 2022).

Fungsi loss menggunakan Log Loss sebagai standar untuk klasifikasi biner. Log Loss atau yang disebut logarithmic loss berfungsi menyeimbangkan label, tidak hanya berdasarkan ukuran relatifnya tetapi juga berdasarkan tingkat kesulitan segmentasi (Wong, Moradi, Tang, & Syeda-Mahmood, 2018).

#### 4. Pelatihan Model

Model dilatih dan divalidasi menggunakan data yang dibagi menjadi 80% Data Latih untuk melatih model dan Data Uji sebanyak 20% untuk mengukur performa model.

Dalam penelitian terdahulu analisis empiris menunjukkan bahwa hasil terbaik dicapai jika kita mengalokasikan 20-30% dari data asli untuk pengujian, dan menggunakan sisanya 70-80% untuk

pelatihan. Didapatkan estimasi akurasi yang valid dan paling akurat di antara estimasi valid (Gholamy, Kreinovich, & Kosheleva, 2018).

### 5. Evaluasi Model

Evaluasi model dilakukan untuk mengukur performa model menggunakan data uji dengan predict() dan membandingkan performa berdasarkan jumlah hidden layer. Kinerja yang ditampilkan seperti akurasi untuk mengukur seberapa tepat prediksi model, presisi untuk mengukur ketepatan prediksi mahasiswa yang benar-benar dropout, recall untuk mengukur sensitivitas model terhadap kasus dropout, dan waktu komputasi waktu dibutuhkan model untuk melatih data pada setiap konfigurasi jumlah hidden layer.

### Alat dan Perangkat Lunak

Penelitian ini menggunakan Python versi 3.12.7 dengan pustaka Scikit-learn untuk implementasi MLP dan

evaluasi model, pandas untuk pengelolaan data, numpy untuk perhitungan numerik, dan matplotlib serta seaborn untuk visualisasi hasil.

Library Pandas memungkinkan klasifikasi berdasarkan sampel pelatihan, yang memastikan persentase pengenalan yang tinggi, serta mengidentifikasi kesesuaian suatu data dengan salah satu dari beberapa kluster (Menailov, Bazilevych, Fedulov, Goranina, & Chumachenko, 2019). NumPy adalah library utama untuk pemrograman array di Python (Harris et al., 2020).

## HASIL DAN PEMBAHASAN

### Hasil Implementasi Model 3 dan 4 hidden layer

Setelah model multilayer perceptron dipersiapkan, evaluasi model perlu dilakukan dengan menampilkan hasil prediksi dari kedua jenis hidden layer.

**Tabel 1.** Hasil Label Prediksi Data Mahasiswa

	Mahasiswa Index	Label Asli (angka)	Label Asli	Label Prediksi (angka)	Label Prediksi
1	0	0	Aktif	0	Aktif
2	1	0	Aktif	0	Aktif
3	2	0	Aktif	0	Aktif
4	3	2	Potensi Lulus	2	Potensi Lulus
5	4	2	Potensi Lulus	2	Potensi Lulus
6	5	4	Drop Out	4	Drop Out
7	6	2	Potensi Lulus	2	Potensi Lulus
8	7	2	Potensi Lulus	2	Potensi Lulus
9	8	4	Drop Out	4	Drop Out
10	9	2	Potensi Lulus	2	Potensi Lulus
11	10	2	Potensi Lulus	2	Potensi Lulus
12	11	4	Drop Out	4	Drop Out
13	12	0	Aktif	0	Aktif
14	13	0	Aktif	0	Aktif
15	14	4	Drop Out	4	Drop Out

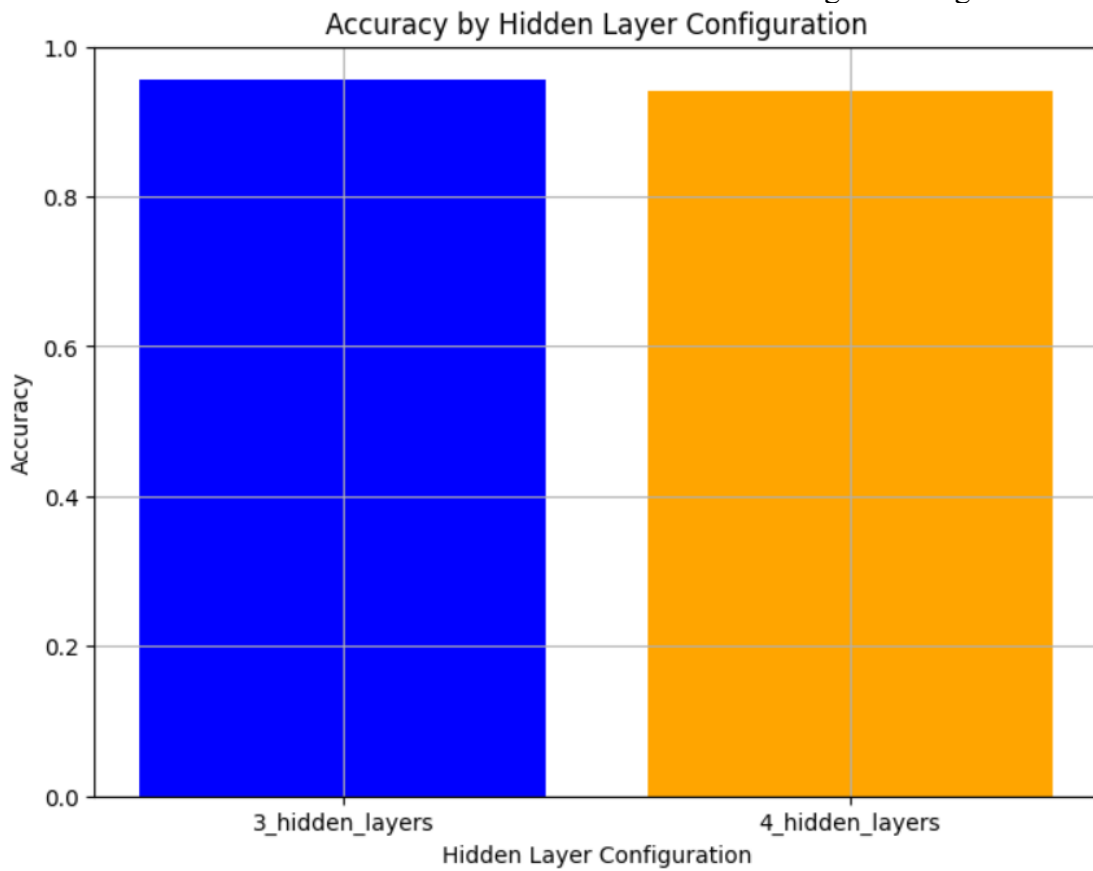
Dalam Tabel 1, Ditemukan hasil prediksi yang sesuai dengan label awal pada setiap data mahasiswa. Hampir semua hasil prediksi di 3 hidden layer maupun 4

sesuai sehingga sulit ditemukan mana yang paling akurat.

Maka dari itu hasil evaluasi akurasi dan waktu latih dari kedua nilai hidden layer tidak lupa pula dipaparkan

agar mengetahui perbedaan dari kedua arsitektur multilayer perceptron tersebut.

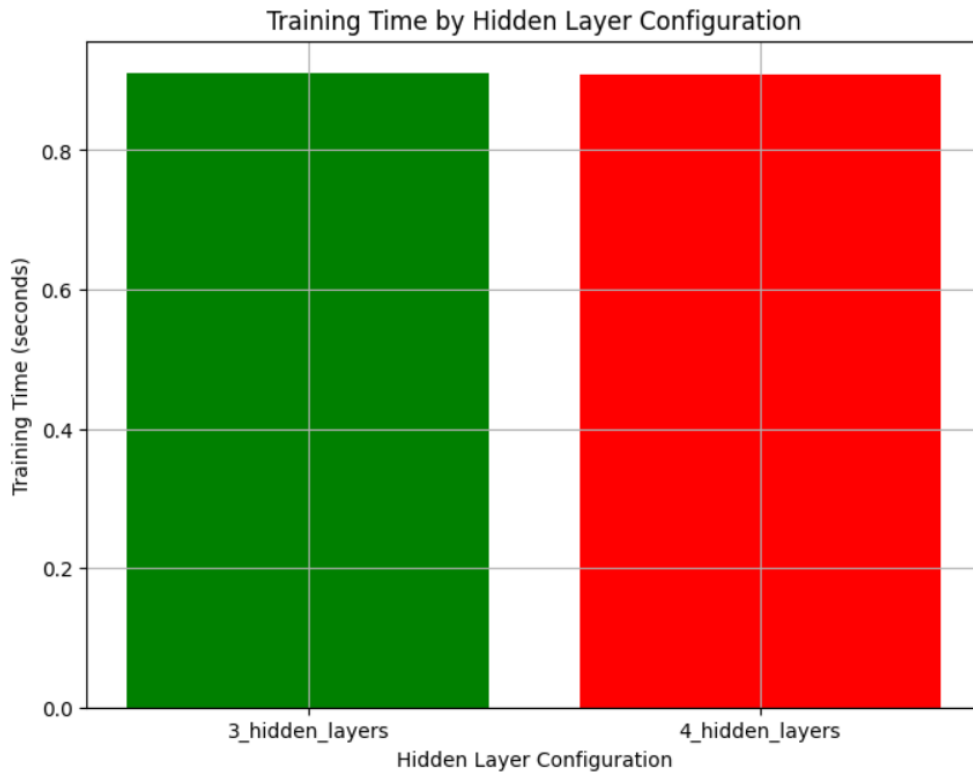
Adapun laporan akurasi dari tiap konfigurasi 3 dan 4 hidden layer disajikan dalam bentuk diagram sebagai berikut.



**Gambar 4.** Diagram Batang Akurasi Konfigurasi Hidden layer

**Tabel 2.** Perbedaan Akurasi dan Waktu Latih 3 dan 4 Hidden Layer

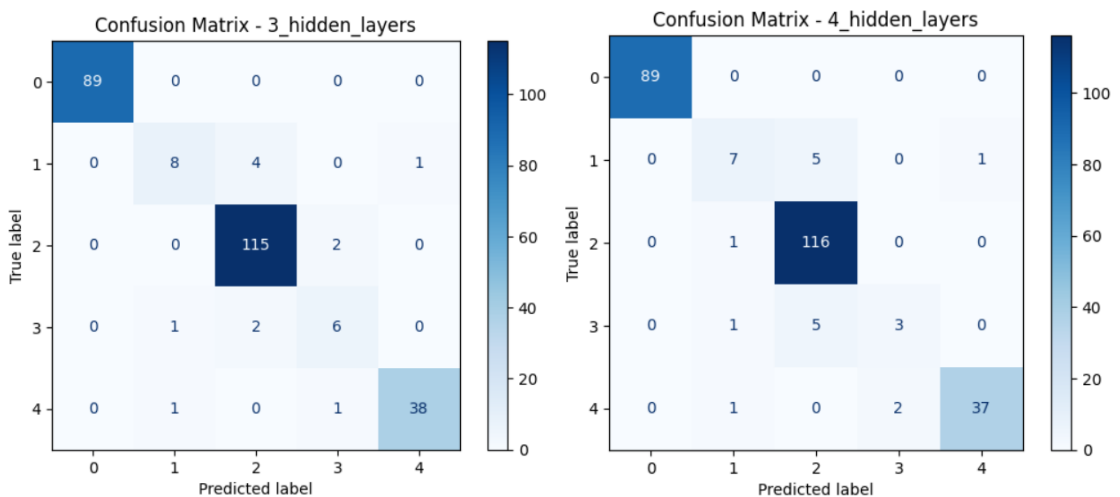
	3 hidden layer	4 hidden layer
Accuration	0.9552	0.9403
Training time	0.8583	0.8727



**Gambar 5.** Diagram Training Time Hidden Layer

Empat hidden layer menunjukkan akurasi sebesar 0.94 atau lebih tepatnya 0.9403. Namun 3 hidden layer menunjukkan nilai akurasi yang didapatkan lebih tinggi yaitu 0.96 tepatnya 0.9552 atau 96%.

Sedangkan untuk waktu pelatihan 3 hidden layer lebih cepat 0.0256 detik dari 4 hidden layer. Diketahui di sini 3 hidden layer lebih cepat dari 4 hidden layer yang dapat dilihat dari diagram diagram pada Gambar 5.



**Gambar 6.** Confusion Matrix 3 dan 4 Hidden layer

Hasil evaluasi menunjukkan perbandingan kinerja antara konfigurasi 3 dan 4 hidden layer berdasarkan confusion matrix. Pada label Aktif, kedua konfigurasi memiliki performa identik dengan 89 prediksi benar. Untuk label Lulus, konfigurasi 3 hidden layer sedikit lebih

unggul dengan 8 prediksi benar dibandingkan 7 pada konfigurasi 4 hidden layer, meskipun tingkat kesalahan prediksinya serupa. Pada label Potensi Lulus, konfigurasi 4 hidden layer unggul dengan 116 prediksi benar dibandingkan 115 pada konfigurasi 3 hidden layer.

Sebaliknya, pada label Potensi Dropout, konfigurasi 3 hidden layer menunjukkan performa lebih baik dengan 6 prediksi benar dibandingkan 3 pada konfigurasi 4 hidden layer, yang lebih sering salah memprediksi ke kategori Potensi Lulus. Pada label Dropout, konfigurasi 3 hidden layer mencatat 38 prediksi benar, sedikit lebih tinggi dibandingkan 37 pada konfigurasi 4 hidden layer. Secara keseluruhan, hasil evaluasi ini

menunjukkan bahwa konfigurasi 4 hidden layer memiliki keunggulan dalam akurasi prediksi pada label Potensi Lulus, sementara konfigurasi 3 hidden layer lebih baik dalam memprediksi Potensi Dropout dan Dropout dengan tingkat kesalahan yang lebih rendah. Kedua konfigurasi menunjukkan kinerja yang stabil tanpa adanya indikasi overfitting atau underfitting yang signifikan.

**Tabel 3.** Kinerja Struktur 3 Hidden Layer

```

Training MLP dengan konfigurasi: 3_hidden_layers ((70, 70, 70))
Akurasi Pelatihan: 0.9476
Akurasi: 0.9552
Training Time: 0.9446
Classification Report:

```

	precision	recall	f1-score	support
0	1.00	1.00	1.00	89
1	0.80	0.62	0.70	13
2	0.95	0.98	0.97	117
3	0.67	0.67	0.67	9
4	0.97	0.95	0.96	40
accuracy			0.96	268
macro avg	0.88	0.84	0.86	268
weighted avg	0.95	0.96	0.95	268

**Tabel 4.** Kinerja Struktur 4 Hidden Layer

```

Training MLP dengan konfigurasi: 4_hidden_layers ((70, 70, 70, 70))
Akurasi Pelatihan: 0.9504
Akurasi: 0.9403
Training Time: 0.9086
Classification Report:

```

	precision	recall	f1-score	support
0	1.00	1.00	1.00	89
1	0.70	0.54	0.61	13
2	0.92	0.99	0.95	117
3	0.60	0.33	0.43	9
4	0.97	0.93	0.95	40
accuracy			0.94	268
macro avg	0.84	0.76	0.79	268
weighted avg	0.93	0.94	0.93	268

### Pembahasan Implementasi Model MLP 3 dan 4 hidden layer

Data mahasiswa yang terancam dropout didapatkan dari data historis mahasiswa melalui pihak universitas.

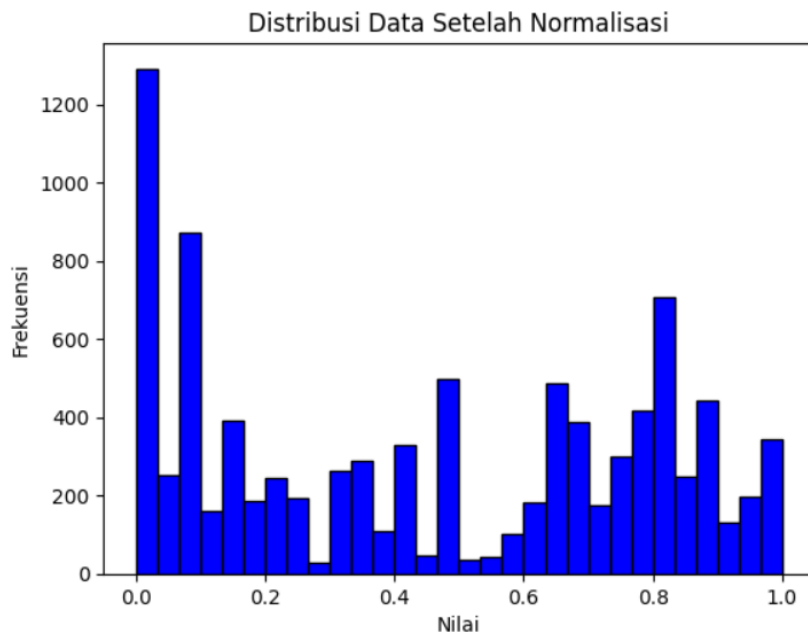
Data yang sudah dikumpulkan tadi lalu dinormalisasi dan dihilangkan missing valuenya. Normalisasi data adalah proses penyesuaian variabel agar memiliki rentang nilai yang seragam, sehingga tidak ada nilai yang terlalu besar atau terlalu kecil. Hal ini bertujuan untuk

mempermudah analisis statistik (Kusnaldi, Gulo, & Aripin, 2022). Adapun teknik yang digunakan untuk normalisasi data pada penelitian ini yaitu memakai fungsi Minmax Scaler. Setelah dimasukkan fungsi tersebut data menunjukkan bahwa sudah dinormalisasi dengan bukti bahwa histogram hanya pada rentan (0,1) pada Gambar 6.

Missing value adalah masalah dalam menjaga kualitas data. Missing value dapat terjadi karena berbagai alasan, salah satunya disebabkan oleh kesalahan saat proses entri data (Lutfi & Hasyim,

2019). Maka dari itu data yang terdapat missing value harus dihapus agar tidak mengganggu model untuk menjalankan klasifikasi. Berikut ini bukti bahwa dataset yang digunakan sudah bebas dari missing value.

Setelah menghilangkan missing value dan menormalisasi data, eksekusi model klasifikasi dilakukan dengan menggunakan 3 dan 4 hidden layer dengan menentukan data uji dan data latih. Data uji sebesar 20% saja dipakai sedangkan untuk data latih yaitu sisanya 80% yang digunakan.



**Gambar 7.** Histogram Normalisasi Data

**Tabel 5.** Tidak Adanya Missing Value

#	Column	Non-Null Count	Dtype
0	Mahasiswa	1337 non-null	object
1	tahun_masuk	1337 non-null	int64
2	lama_studi	1337 non-null	int64
3	ips	1337 non-null	float64
4	ipk	1337 non-null	float64
5	sksemester	1337 non-null	int64
6	total_sks	1337 non-null	int64
7	biaya_kuliah	1337 non-null	int64
8	label	1337 non-null	int64

Pada model dengan 3 hidden layer, nilai (70, 70, 70) adalah tuple yang menunjukkan bahwa ada 70 neuron di setiap lapisan tersembunyi. Sedangkan 4 hidden layer hanya menambahkan 70 neuron lagi sehingga value menjadi (70, 70, 70, 70).

Inisialisasi model multilayer perceptron ini dilakukan dengan cara memasukkan fungsi MLPClassifier yang berisi parameter yaitu fungsi aktivasi, algoritma Adam untuk optimasi penyesuaian bobot, iterasi maksimal senilai 1000, learning rate yaitu dimulai dengan

angka 0.001. Semua inisialisasi ini digunakan untuk kedua jenis model yang sama dengan hidden layer yang berbeda tadi.

Pernyataan pada penelitian terdahulu bahwa proses pelatihan jaringan saraf melambat jika jumlah lapisan tersembunyi yang digunakan terlalu banyak. Oleh karena itu, jika kriteria masalah adalah untuk mencapai akurasi yang lebih baik, maka menggunakan jumlah lapisan tersembunyi yang banyak merupakan solusi yang paling cocok. Namun, jika kompleksitas waktu menjadi faktor utama dalam suatu aplikasi, maka jumlah lapisan tersembunyi yang banyak tidak akan efektif untuk jenis aplikasi tersebut (Uzair & Jamil, 2020).

Dalam kasus ini walaupun jumlah hidden layer ada 4, akurasi yang diperoleh jauh lebih kecil dan prediksi yang tepat selisih 2 lebih kecil daripada yang berjumlah 3 hidden layer. Untuk kompleksitas waktu lebih cepat dengan menggunakan 3 lapisan tersembunyi dengan jumlah data 256 yang berhasil diprediksi dengan tepat. Maka 3 hidden layer adalah jumlah hidden layer yang paling optimal untuk mengklasifikasi model.

## KESIMPULAN

Sebagai kesimpulan untuk mencapai hasil akurasi terbaik maka 3 hidden layer adalah jumlah hidden layer yang paling cocok untuk digunakan pada model klasifikasi algoritma multilayer perceptron menggunakan Scikit-learn untuk data mahasiswa yang terancam dropout. Alasannya adalah bahwa waktu latih yang digunakan tidak terlalu lama dan hasil akurasi yang didapatkan juga besar tidak seperti jumlah hidden layer yang melebihi 3 hidden layer.

Meskipun demikian, model ini bisa diintegrasikan ke dalam sistem akademik untuk membantu kampus atau institusi dalam mengatasi masalah mahasiswa yang terancam dropout.

Penulis menyadari bahwa masih ada kekurangan pada penulisan, untuk kedepannya diharapkan agar para peneliti

yang menganalisa jumlah hidden layer agar membuat model yang sama tidak hanya mengikuti arsitektur dalam penelitian ini saja. Tetapi juga harus terus bereksperimen memakai berbagai ragam jumlah neuron ataupun hidden layer sampai menemukan hasil prediksi yang akurat dan tepat.

## DAFTAR PUSTAKA

- Bisong, E. (2019). Introduction to Scikit-learn. In *Building Machine Learning and Deep Learning Models on Google Cloud Platform: A Comprehensive Guide for Beginners* (pp. 215–229). Berkeley, CA: Apress. [https://doi.org/10.1007/978-1-4842-4470-8\\_18](https://doi.org/10.1007/978-1-4842-4470-8_18)
- Dharmalingam, B., Annamalai, S., Areeya, S., Rattanaporn, K., Katam, K., Show, P. L., & Sriariyanun, M. (2023). Bayesian Regularization Neural Network-Based Machine Learning Approach on Optimization of CRDI-Split Injection with Waste Cooking Oil Biodiesel to Improve Diesel Engine Performance. *Energies*. Retrieved from <https://api.semanticscholar.org/CorpusID:257651964>
- Gholamy, A., Kreinovich, V., & Kosheleva, O. (2018). *Why 70/30 or 80/20 Relation Between Training and Testing Sets: A Pedagogical Explanation*. Retrieved from <https://api.semanticscholar.org/CorpusID:7467506>
- Harris, C. R., Millman, K. J., van der Walt, S., Gommers, R., Virtanen, P., Cournapeau, D., ... Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, 585, 357–362. Retrieved from <https://api.semanticscholar.org/CorpusID:219792763>
- Hasan, Md. M., Hossain, Md. A., Srizon, A. Y., & Sayeed, A. (2023). TaLU: A Hybrid Activation Function Combining Tanh and Rectified Linear Unit to Enhance Neural Networks. *ArXiv, abs/2305.04402*. Retrieved from <https://api.semanticscholar.org/CorpusID:258557862>
- Kusnaldi, M. R., Gulo, T., & Aripin, S. (2022). Penerapan Normalisasi Data Dalam Mengelompokkan Data Mahasiswa Dengan Menggunakan Metode K-Means Untuk Menentukan Prioritas Bantuan Uang Kuliah Tunggal. *Journal of Computer System and*

- Informatics (JoSYC)*. Retrieved from <https://api.semanticscholar.org/CorpusID:255743400>
- Lutfi, M., & Hasyim, M. (2019). PENANGANAN DATA MISSING VALUE PADA KUALITAS PRODUKSI JAGUNG DENGAN MENGGUNAKAN METODE K-NN IMPUTATION PADA ALGORITMA C4.5. *Jurnal RESISTOR (Rekayasa Sistem Komputer)*. Retrieved from <https://api.semanticscholar.org/CorpusID:209927737>
- Maiyuriska, R. (2022). Penerapan Jaringan Syaraf Tiruan dengan Algoritma Backpropagation dalam Memprediksi Hasil Panen Gabah Padi. *Jurnal Informatika Ekonomi Bisnis*. Retrieved from <https://api.semanticscholar.org/CorpusID:247355667>
- Meniailov, I., Bazilevych, K., Fedulov, K., Goranina, S., & Chumachenko, D. (2019). Using the K-means Method for Diagnosing Cancer Stage Using the Pandas Library. *Modern Machine Learning Technologies*. Retrieved from <https://api.semanticscholar.org/CorpusID:195693718>
- Ren, R., Su, J., Yang, B., Lau, R. Y. K., & Liu, Q. (2022). Novel Low-Power Construction of Chaotic S-Box in Multilayer Perceptron. *Entropy*, *24*(11). <https://doi.org/10.3390/e24111552>
- Rivan, M. E. Al, & Sung, G. R. (2021). *Identifikasi Mutu Buah Pepaya California (Carica Papaya L.) Menggunakan Metode Jaringan Syaraf Tiruan*. Retrieved from <https://api.semanticscholar.org/CorpusID:235562762>
- Uzair, M., & Jamil, N. (2020). Effects of Hidden Layers on the Efficiency of Neural networks. *Proceedings - 2020 23rd IEEE International Multi-Topic Conference, INMIC 2020*. Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/INMIC50486.2020.9318195>
- Wong, K. C. L., Moradi, M., Tang, H., & Syeda-Mahmood, T. F. (2018). 3D Segmentation with Exponential Logarithmic Loss for Highly Unbalanced Object Sizes. *ArXiv, abs/1809.00076*. Retrieved from <https://api.semanticscholar.org/CorpusID:52157209>
- Zheng, Y., Wang, R., Chen, C., & Meng, F. (2022). Fast stability assessment of rock slopes subjected to flexural toppling failure using adaptive moment estimation (Adam) algorithm. *Landslides*, *19*, 2149–2158. Retrieved from <https://api.semanticscholar.org/CorpusID:248894183>