

# Algoritma Multi Layer Perceptron sebagai Prediksi Kelulusan Mahasiswa Universitas Adzkia Tepat Waktu berdasarkan jenis kelamin, Indeks Prestasi Semester, dan Jumlah SKS

Deryla Mardinah<sup>1</sup>, Muhammad Thoriq<sup>2</sup>

<sup>1,2,3</sup>Program Studi Informatika, Universitas Adzkia, Indonesia

## Article Info (10 pt)

### Article history:

Received, 10 Juli 2024  
Revised, 18 Juli 2024  
Accepted, 01 Agustus 2024

### Kata Kunci:

Artificial Intelligence,  
Prediksi Status Kelulusan  
Mahasiswa,  
Multilayer Perceptron,  
Python,  
Machine Learning.

## ABSTRAK

Dalam proses akreditasi perguruan tinggi, kelulusan akademik mahasiswa digunakan sebagai kriteria penilaian. Data kelulusan siswa yang tersimpan dapat digunakan untuk membuat prediksi di masa depan. Prediksi dapat diukur dengan menggunakan AI untuk menghasilkan prediksi yang akurat berdasarkan data siswa selama enam semester, yaitu gender, IPS1-6, dan SKS1-6. Untuk memprediksi status kelulusan siswa, penelitian ini menggunakan Jaringan Syaraf Tiruan Multi-Layer Perceptron (JST MLP). Digunakan sebagai prediktor, fitur terdiri dari tiga belas atribut. Nilai biner satu menunjukkan lulus tepat waktu dan 0 menunjukkan tidak lulus tepat waktu dalam kelas target. JST MLP yang diusulkan terdiri dari tiga lapisan: lapisan masukan yang terdiri dari tiga belas neuron, lapisan tersembunyi yang terdiri dari dua belas neuron, dan lapisan keluaran yang terdiri dari satu neuron. Aplikasi yang digunakan melalui Python Google Colab. Sebanyak 100 epochs digunakan untuk memberikan instruksi. Hasilnya mencakup bobot untuk setiap neuron dalam MLP. Nilai metrik akurasi model sebesar 95% menunjukkan bahwa prediksi memiliki tingkat akurasi yang baik.

*This is an open access article under the [CC BY-NC](https://creativecommons.org/licenses/by-nc/4.0/) license.*



## Corresponding Author: (10pt)

Deryla Mardinah,  
Program Studi Informatika,  
Universitas Adzkia Sumatera Barat,  
Jl. Taratak Paneh No. 7 Korong Gadang, Kalumbuk, Kec. Kuranji, Kota Padang, Sumatera Barat.  
Email: [mardinah089@gmail.com](mailto:mardinah089@gmail.com)

## 1. PENDAHULUAN

Setiap lembaga pendidikan menerapkan sistem kelulusan bagi setiap mahasiswanya yang menjalani studi selama pembelajaran, termasuk Universitas Adzkia. Kelulusan Studi mahasiswa menjadi indikator penilaian dalam akreditasi perguruan tinggi. Landasan penilaian kualitas lembaga pendidikan yang ditetapkan oleh Badan Akreditasi Nasional (BAN) adalah penilaian berdasarkan ketepatan waktu mahasiswa menyelesaikan pembelajaran yang efisiensi dan efektif. Setiap tahun perguruan tinggi memberikan standar kelulusan berdasarkan Indeks Prestasi Semester/Kumulatif dan jumlah Satuan Kredit Semester. Pada Kampus Universitas Adzkia, batas yang telah ditentukan untuk lulus tepat waktu adalah IPK 2-4 dan SKS 144-150.

Data kelulusan mahasiswa yang tersimpan dapat diolah menjadi suatu informasi yang berguna sebagai prediksi dimasa depan. Prediksi kelulusan dapat digunakan untuk mengembangkan kurikulum dan menerapkan kebijakan yang sesuai dengan kecenderungan yang terjadi, prediksi lulusan juga diperlukan untuk mengukur kesalahan atau selisih antara perkiraan dengan studi hasil yang terjadi. Masa sekarang prediksi dapat diukur dengan memanfaatkan Artificial Intelligence dalam membantu solusi manusia. Alur metode yang digunakan dalam prediksi mulai dari menghimpun data, melakukan klasifikasi dan perhitungan. Adapun data kelulusan mahasiswa yang dibutuhkan yaitu jenis kelamin, nilai IPS1-IPS6 dan SKS1-SKS6 dari semester 1 hingga semester 6.

Banyak algoritma yang digunakan sebagai metode prediksi dalam data mining termasuk Support Vector Machine (SVM), Neural Network (NN), dan Grey Model (GM). Algoritma Machine Learning, khususnya Algoritma Multi-Layer Perceptron (MLP), telah terbukti efektif dalam berbagai aplikasi prediksi dan klasifikasi. Perceptron Multilayer MLP adalah jenis jaringan saraf buatan (artificial neural network) yang paling banyak digunakan dalam pembelajaran mesin untuk pemodelan jaringan saraf tidak linear dan non deterministik. MLP terdiri dari beberapa lapisan neuron: lapisan masukan (input layer), lapisan tersembunyi (hidden layer), dan lapisan keluaran (output layer). Untuk meminimalkan perbedaan antara jaringan output dan output yang diinginkan, multilayer perceptron MLP menyesuaikan koneksi bobot.

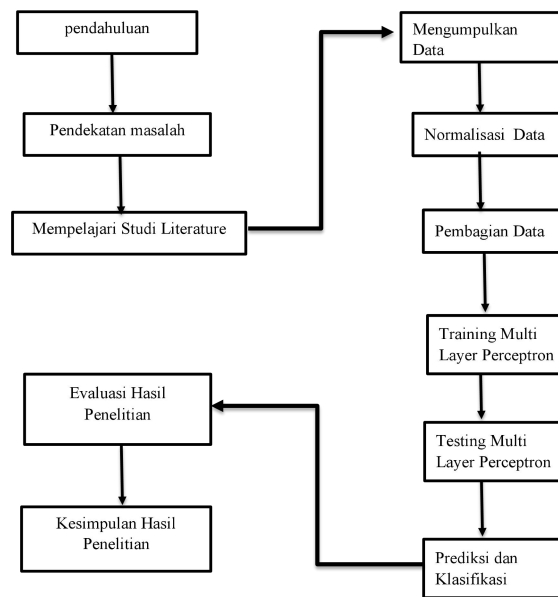
Penerapan MLP dalam prediksi kelulusan mahasiswa dapat memberikan kontribusi yang signifikan dalam meningkatkan efisiensi pengelolaan dan membantu mahasiswa dalam menyelesaikan studinya tepat waktu. Berdasarkan penelitian sebelumnya yang menggunakan metode yang MLP yaitu :

1. Amrin dan Irawan Satriadi(2018) melakukan penelitian dengan judul Implementasi Jaringan Syaraf Tiruan Dengan Multilayer Perceptron Untuk Analisa Pemberian Kredit dalam menganalisa pemberian kredit. Studi tersebut menemukan akurasi 96,1%.
2. Muhammad Ibnu Sa'ad (2023) melakukan penelitian dengan judul Perbandingan Algoritma Extreme Learning Machine dan Multilayer Perceptron Dalam Prediksi Mahasiswa Drop Out. Dengan membandingkan 2 metode yang berbeda. Studi tersebut menemukan akurasi 91%.
3. Khoirudin, Dewi Nurdiyah , Nur Wakhidah (2018) melakukan penelitian dengan judul Prediksi Penerimaan Mahasiswa Baru Dengan Multi Layer Perceptron. Studi tersebut menemukan akurasi 95% .
4. Rusma Insan Nurachim (2019) melakukan penelitian dengan judul Pemilihan Model Prediksi Indeks Harga Saham Yang Dikembangkan Berdasarkan Algoritma Support Vector Machine(Svm) Atau Multilayer Perceptron(Mlp) Studi Kasus : Saham Pt Telekomunikasi Indonesia Tbk. Studi tersebut menemukan akurasi 92,5%.
5. Ahmad Fadli Ramadhan, Rizal Adi Saputra(2023) melakukan penelitian dengan judul Prediksi Jumlah Penumpang Bandar Udara Halu Oleo Kendari Menggunakan Multi-layer Perceptron. Studi tersebut menemukan akurasi 96%.

Setelah melakukan studi kasus pada penelitian terdahulu, peneliti mencoba menggunakan metode ini untuk mengumpulkan data dari mahasiswa Universitas Adzkie. Data ini mencakup jenis kelamin, IPS, jumlah SKS yang ditempuh, dan status kelulusan mahasiswa (tepat waktu atau tidak tepat waktu). Data ini akan digunakan untuk melatih dan menguji model MLP. Analisis hasil akan memberikan pemahaman yang lebih mendalam tentang komponen yang paling berpengaruh terhadap kelulusan mahasiswa tepat waktu. Dengan demikian, penelitian ini memiliki potensi untuk memberikan kontribusi dalam meningkatkan kualitas pendidikan tinggi, khususnya dalam Universitas Adzkie, melalui penerapan teknologi Machine Learning untuk prediksi kelulusan mahasiswa tepat waktu.

## 2. METODOLOGI PENELITIAN

Studi ini disusun secara sistematis sesuai dengan tujuan yang ingin dicapai. Proses pembuatan model prediksi drop out mahasiswa dengan Multilayer Perceptron adalah sebagai berikut: pengumpulan data; penerapan metode Multilayer Perceptron untuk prediksi melalui pembagian data; pelatihan dan pengujian; dan analisis hasil prediksi. Penelitian dimulai dengan pendahuluan dan pendekatan masalah. Tujuan dari penelitian ini adalah untuk meningkatkan pemahaman kita tentang bagaimana metode Multilayer Perceptron berfungsi, serta tahapan apa yang diperlukan untuk membuat prediksi menggunakan metode ini. Selain itu, literatur juga dipelajari untuk mengetahui bagaimana siswa meninggalkan kelas untuk meningkatkan fokus pengumpulan data. Pengumpulan data adalah langkah kedua dari penelitian ini. Tahap ketiga melibatkan penerapan metode Multilayer Perceptron melalui pembagian data, pelatihan, dan pengujian. Berikut ini adalah langkah-langkah yang diambil untuk mempersiapkan rancangan penelitian:



Gambar 1. Alur Metode Penelitian

### 2.1. Instrumen Penelitian

Instrumen penelitian digunakan untuk mengubah data menjadi informasi bermanfaat. Penelitian ini menggunakan data lulusannya Mahasiswa Universitas Adzkie. Selanjutnya, data diproses menggunakan aplikasi Google COLAB 3.10 bahasa pemrograman python untuk mengetahui prediksi tingkat kelulusan mahasiswa yang akurat.

### 2.2. Artificial Intelligence

Artificial Intelligence adalah istilah yang pertama kali digunakan pada tahun 1956 di sebuah konferensi di bidang komputer di Dartmouth. Pada awalnya, kecerdasan buatan dirancang untuk memodelkan cara otak manusia bekerja. Metode ini kemudian dapat digunakan sebagai dasar untuk membangun sistem komputer yang lebih cerdas. Berdasarkan rumusan awal ini, Poole, Mackworth, dan Goebel (Poole, Mackworth, & Goebel, 1998) mendefinisikan "artificial intelligence" sebagai bidang ilmu yang menyelidiki pengembangan agen kecerdasan buatan. Definisi di atas lebih menekankan penelitian tentang kecerdasan buatan pada kemampuan komputer untuk meniru kemampuan kognitif (berfikir) manusia, yaitu kemampuan untuk mengatasi masalah dan belajar. Dalam dua puluh tahun terakhir, beberapa cabang ilmu tentang AI telah muncul. Setiap cabang mengkaji bidang yang lebih khusus dari AI. Machine Learning dan Deep Learning adalah cabang AI yang berkembang paling cepat dan telah digunakan dalam berbagai teknologi industri.

### 2.3. Machine Learning

Samuel (2021) menyatakan bahwa mesin pembelajaran mesin termasuk algoritma yang bersifat generic (umum), yang memiliki kemampuan untuk menghasilkan sesuatu yang menarik atau bermanfaat dari sejumlah data tanpa harus menulis kode tertentu. Pada dasarnya, algoritma generik dapat membangun aturan, model, atau inferensi dari data yang diberikan kepadanya.

### 2.4. Algoritma Neural Network

Artificial neural network, juga dikenal sebagai neural network (NN), adalah sistem pemrosesan informasi dengan fitur yang mirip dengan jaringan saraf biologis. Salah satu komponen soft computing, artificial neural network, mengutamakan proses berpikir melalui pendekatan daripada yang eksak. Soft computing sangat fleksibel, toleran terhadap ketidakpresisian, ketidakpastian, dan kebenaran parsial, serta lebih presisi daripada hard computing tradisional. Tujuan utama soft computing adalah untuk menggunakan toleransi ini untuk menjadi menarik, tahan lama, kecerdasan mesin tingkat tinggi, dan mudah digunakan (Lin & Lee, 1996).

#### a. Pengumpulan Data

Data yang diumpulkan berdasarkan data kelulusan Mahasiswa Universitas Adzkie yang lulus Tepat Waktu dan Tidak Lulus Tepat Waktu. Sebanyak 100 sampel, dengan 13 atribut berdasarkan nama, jenis kelamin, nilai IPS1-6, dan jumlah SKS yang diambil dari semester 1-6.

### b. Normalisasi Data

Normalisasi data digunakan untuk mentransformasikan data kelulusan mahasiswa menjadi range baru. Untuk data IPS dan SKS metode normalisasi yang digunakan adalah metode Minmax sebagai berikut :

$$v' = \frac{v - \text{Min}_A (\text{NewMax}_A - \text{NewMin}_A)}{\text{Max}_A - \text{Min}_A} + \text{New\_Min}_A \quad (1)$$

Keterangan :

$v'$ : data baru hasil normalisasi

$v$  = data lama yang akan dinormalisasi

$\text{Min}_A$  = nilai terkecil kolom A

$\text{Max}_A$  = nilai terbesar kolom A

$\text{New\_min}_A$  = batas nilai terkecil dari normalisasi

$\text{New\_max}_A$  = batas nilai terbesar dari normalisasi

Adapun untuk data gender dan status kelulusan pada data kelulusan mahasiswa akan diproses terlebih dahulu dengan mengubah status “LULUS TEPAT WAKTU” dan “Male” menjadi angka 1 atau “TIDAK LULUS TEPAT WAKTU “ dan “Female” menjadi angka 0.

### c. Metode pembagian data training dan data testing Menggunakan Algoritma MLP.

Penelitian ini menggunakan neural network sebagai proses training dari hasil pengumpulan data. Dalam proses training. Dari hasil normalisasi data tersebut kemudian data ditraining menggunakan MLP. Dari 100 sampel data mahasiswa dilakukan 80% sebagai data training dan 20% menjadi data testing. Proses klasifikasi biasanya terdiri dari dua proses:

- 1) Proses training: dalam proses ini, set pelatihan digunakan untuk membangun model atau fungsi.
- 2) Proses testing : dalam proses ini, set pengujian digunakan untuk memprediksi label label model atau fungsi yang akan dibangun dalam proses pelatihan.

### d. Multi Layer Perceptron

Jaringan syaraf tiruan feedforward yang menghasilkan keluaran dari berbagai masukan dikenal sebagai perceptron multilayer. Multilayer Perceptron menghubungkan berbagai lapisan node masukan sebagai grafik berarah antara lapisan masukan dan keluaran. Metode pembelajaran mendalam Multilayer Perceptron menggunakan propagasi mundur untuk melatih jaringan. Multilayer Perceptron terdiri atas 3 layer yaitu input layer, hidden layer, dan output layer. Berikut langkah-langkah algoritma MLP :

- 1) Inisiasi bobot, dengan menggunakan range acak antara 0 hingga 1.
- 2) Inisiasi bias, dengan menggunakan bias acak antara 0 hingga 1.
- 3) Menghitung besarnya input dari input layer menuju hidden layer dengan rumus.

$$\text{Input}_j = \sum_{i=1}^n O_i W_{ij} + O_j^- \quad (2)$$

Keterangan

$O_i$  = output simpul  $I$  dari layer sebelumnya.

$W_{ij}$  = bobot relasi dari simpul  $i$  pada layer.

$O_j^-$  = bias(sebagai pembatas).

- 4) Setelah langkah ke 3, dilanjutkan dengan pembangkitan output dari hidden layer menuju output layer. Dengan menggunakan fungsi aktivasi tansig atau sigmoid bipolar.

$$F(\text{net}) = \frac{2}{1 + e^{-\text{net}}} - 1 \quad (3)$$

- 5) Hitung nilai error antara prediksi dengan nilai sesungguhnya dengan rumus :

$$\text{Error} = \text{Output} \cdot (1 - \text{Output}) \cdot (\text{Target } j - \text{Output } j) \quad (4)$$

Keterangan

$\text{Output } j$  = Output aktual dari simpul  $j$

$\text{Target } j$  = Nilai target yang diketahui pada data training

- 6) Setelah nilai error dihitung, selanjutnya kembali ke layer sebelumnya, untuk menghitung error pada hidden layer dengan rumus :

$$\text{Error} = \text{Output}_j \cdot (1 - \text{Output}_j) \cdot \sum_{k=1}^n \text{Error}_k W_{jk} \quad (5)$$

Keterangan

Output<sub>j</sub> = Output aktual dari simpul j

Error<sub>k</sub> = Error simpul k w<sub>jk</sub> = Bobot relasi dari simpul j ke simpul k pada layer berikutnya

- 7) Nilai error sebelumnya digunakan untuk memperbaiki bobot

$$W_{IJ} = W_{IJ} + l \cdot \text{Error}_j \cdot \text{Output}_i \quad (6)$$

Keterangan

W<sub>IJ</sub> = Bobot relasi dari unit i pada, layer sebelumnya ke unit j

l = learning rate (konstanta, nilainya antara 0 sampai dengan 1.

- 8) Iterasi MLP akan berhenti jika sudah memenuhi maksimal epoch yang ditentukan atau memenuhi mse yang ditentukan atau error bernilai 0.

#### e. Perhitungan akurasi

Ukuran kinerja jaringan saraf adalah dihitung dengan menggunakan berbagai ukuran seperti akurasi, presisi dan spesifisitas dan sensitivitas. Perhitungan sebagai berikut:

$$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN}) \quad (7)$$

$$\text{Specificity} = \text{TN} / (\text{TN} + \text{FP})$$

$$\text{Sensitivity} = \text{TP} / (\text{TP} + \text{FN})$$

Keterangan

TP = True Positive, adalah jumlah sampel yang diklasifikasikan lulus tepat waktu dan benar lulus tepat waktu

TN = True Negative, adalah jumlah sampel yang diklasifikasikan sebagai akan tidak lulus tepat waktu dan memang benar jika mereka sebenarnya tidak lulus tepat waktu

FN = False Negative, adalah jumlah sampel yang diklasifikasikan sebagai tidak lulus tepat waktu ternyata mereka lulus tepat waktu

FP = False Positive, adalah jumlah sampel yang diklasifikasikan sebagai kategori lulus tepat waktu padahal mereka sebenarnya tidak lulus tepat waktu

### 3. HASIL DAN PEMBAHASAN

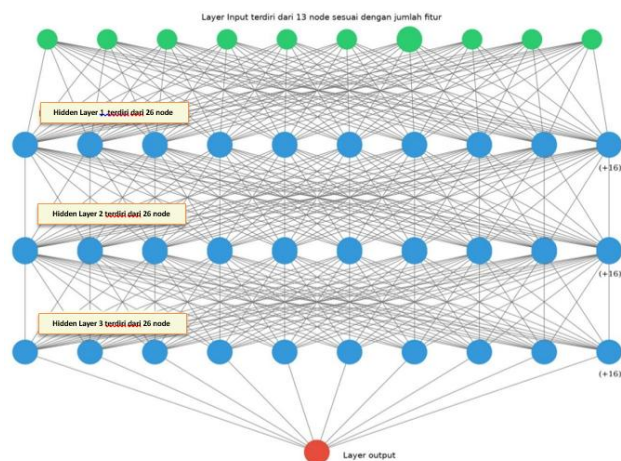
#### 3.1 Data Olah

Aplikasi Python dapat digunakan untuk melakukan perkiraan dengan algoritma Multilayer Perceptron. Perkiraan yang akan lulus dengan algoritma MLP dibuat dengan membagi informasi menjadi dua bagian: satu untuk data pelatihan dan satu lagi untuk data uji. Data yang digunakan dalam penelitian ini diperoleh dari biro administrasi akademik kemahasiswaan (BAAK) Universitas Adzka. Sebanyak 100 sampel data mahasiswa dengan 13 atribut yaitu gender, IPS semester 1 sampai 6, dan SKS semester 1-6, mahasiswa untuk memprediksi status kelulusan mahasiswa.

No.	Nama	Gender	SK S1	IP S1	SK S2	IP S2	SK S3	IP S3	SK S4	IP S4	SK S5	IP S5	SK S6	IP S6	STATUS
1.	Muhammad Ilham	Male	24	2,8	19	3,8	22	3,7	19	2,5	19	3,0	20	3,1	Lulus Tepat Waktu
2.	Sintia Ulandari	Female	20	3,1	21	3,8	24	3,1	24	3,5	23	3	24	3,7	Lulus Tepat Waktu
3.	Rizki Maulana	Male	21	2,6	23	2,2	20	3,3	24	3,8	22	3,5	20	3,5	Lulus Tepat Waktu
4.	Ashim Reyhand	Male	24	2,9	22	2,7	18	3	19	3,1	24	1,0	18	2,6	Tidak Lulus Tepat Waktu
...	....	....	....	....	....	....	....	....	....	....	....	....	....	....	.....
97.	Akmal Naufal	Male	18	1,8	20	1,1	24	3,7	21	3,9	19	2,2	19	1,7	Tidak Lulus Tepat Waktu
98.	Esti Maysita	Female	21	1,8	21	3,1	18	3,4	24	3,9	24	3,8	21	3,8	Lulus Tepat Waktu
99.	Deri Dermawan	Male	23	1,6	24	2,1	23	3,6	22	3,2	18	3,5	20	3,5	Lulus Tepat Waktu
100	Alam Gunawan	Male	20	3,9	23	2,7	21	3,0	24	2,3	24	2,9	20	3,5	Lulus Tepat Waktu

### 3.2 Design arsitektur JST - MLP

Seperti yang ditunjukkan pada gambar berikut, arsitektur MLP terdiri dari tiga lapisan: lapisan masukan, lapisan tersembunyi, dan lapisan keluaran. Lapisan pertama terdiri dari 13 neuron dengan dimensi masukan yang sama dengan jumlah atribut prediksi yang dijelaskan pada bab sebelumnya. Lapisan tersembunyi terdiri dari 26 neuron, dua kali lebih banyak dari neuron masukan. Lapisan output terdiri dari satu neuron keluaran. Gambar berikut menunjukkan arsitektur MLP.



Gambar 2. Arsitektur Jaringan Multilayer Perceptron

### 3.3 Implementasi dengan menggunakan python

#### a. Inisiasi Data Awal

Implementasi dilakukan melalui pemrograman menggunakan bahasa pemrograman Python. Dataset disimpan di Google Drive, dan penulis menggunakan mount drive untuk memberi kode yang memungkinkan untuk mengelola dataset yang sudah disimpan di Google Drive. Dalam tahap ini, penulis dapat mengimport library seperti sklearn, pandas, seaborn, dan matplotlib.

```
import pandas as pd
import seaborn as ses
import matplotlib.pyplot as plt

dataset=pd.read_csv('/content/dataset_uas_ai.csv')

dataset=pd.read_csv('/content/dataset_uas_ai.csv')
dataset.head()
```

	gender	sks1	ips1	sks2	ips2	sks3	ips3	sks4	ips4	sks5	ips5	sks6	ips6	sta
0	1	24	2.88	19	3.85	22	3.74	19	2.53	19	3.03	20	3.19	
1	0	20	3.19	21	3.81	24	3.19	24	3.56	23	3.00	24	3.77	
2	1	21	2.63	23	2.21	20	3.39	24	3.86	22	3.56	20	3.54	
3	1	24	2.90	22	2.73	18	3.00	19	3.13	24	1.05	18	2.65	
4	0	22	3.30	18	3.16	23	2.99	18	3.46	21	3.42	19	3.95	

Gambar 3. Inisiasi Data Awal

#### b. Normalisasi Data

Setelah itu, normalisasi dilakukan menggunakan metode Minmax yang memiliki jangkauan -1 hingga 1 menggunakan rumus Minmax.. Pendekatan range ini didasarkan pada fungsi aktivasi tangsig atau sigmoid biner. Gambar 4 menggambarkan hasil normalisasi.

### Membagi Data Training dan Data Latih

```

from sklearn.model_selection import train_test_split

X=dataset_scaled.drop(13, axis=1)
Y=dataset_scaled[13]

X_train, X_test, Y_train, Y_test = train_test_split(X,Y,train_size=0.8)

X_train.shape, X_test.shape
((80, 13), (20, 13))

Y_train.shape, Y_test.shape
((80,), (20,))

```

**NORMALISASI DATA RUMUS MIN MAX  $V' = \frac{v - \min(A)}{\max(A) - \min(A)}$**

```

from sklearn.preprocessing import MinMaxScaler

skala=MinMaxScaler()
scaled = skala.fit_transform(dataset[dataset.columns])
dataset_scaled=pd.DataFrame (scaled)

print(dataset_scaled)

```

	0	1	2	3	4	5	6	7
0	1.0	1.000000	0.609155	0.166667	0.855828	0.666667	0.942652	0.166667
1	0.0	0.333333	0.718310	0.500000	0.843558	1.000000	0.745520	1.000000
2	1.0	0.500000	0.521127	0.833333	0.352761	0.333333	0.817204	1.000000
3	1.0	1.000000	0.616197	0.666667	0.512270	0.000000	0.677419	0.166667
4	0.0	0.666667	0.757042	0.000000	0.644172	0.833333	0.673835	0.000000
..	...	...	...	...	...	...	...	...
95	1.0	0.333333	0.915493	0.833333	0.831288	1.000000	0.376344	0.166667
96	1.0	0.000000	0.242958	0.333333	0.012270	1.000000	0.953405	0.500000
97	0.0	0.500000	0.228873	0.500000	0.625767	0.000000	0.827957	1.000000
98	1.0	0.833333	0.186620	1.000000	0.331288	0.833333	0.903226	0.666667
99	1.0	0.333333	0.989437	0.833333	0.518405	0.500000	0.702509	1.000000

	8	9	10	11	12	13
0	0.487805	0.166667	0.675585	0.333333	0.656347	1.0
1	0.846690	0.833333	0.665552	1.000000	0.835913	1.0

f3 18/01/2024  
 py of DATA\_UAS\_AI - Colaboratory [https://colab.research.google.com/drive/1Iz\\_QC8GkVaubAq-IU8o](https://colab.research.google.com/drive/1Iz_QC8GkVaubAq-IU8o)

2	0.951220	0.666667	0.852843	0.333333	0.764706	1.0
3	0.696864	1.000000	0.013378	0.000000	0.489164	0.0
4	0.811847	0.500000	0.806020	0.166667	0.891641	1.0
..	...	...	...	...	...	...
95	0.742160	1.000000	0.792642	1.000000	0.900929	1.0
96	0.975610	0.166667	0.418060	0.166667	0.213622	0.0
97	0.996516	1.000000	0.959866	0.500000	0.869969	1.0
98	0.735192	0.000000	0.846154	0.333333	0.764706	1.0
99	0.435540	1.000000	0.642140	0.333333	0.764706	1.0

[100 rows x 14 columns]

Gambar 4. Hasil Normalisasi Data

### c. Membagi Data Training Dan Data Testing

Variabel bebas 0,1,2,3,4,5,6,7,8,9,10,11,dan 12. Sedangkan variabel terikat atau target adalah 13.Selanjutnya, dataset yang ditunjukkan dalam tabel 2 dibagi menjadi dua, 80% untuk data pelatihan dan 20% untuk data pengujian.

#### d. Melatih Data Dengan Multi Layer Perceptron

Setelah dibagi menjadi data pelatihan dan pengujian, data kemudian diterapkan ke dalam model multilayer perceptron. Proses model pelatihan multilayer perceptron digambarkan pada gambar 6 berikut: Untuk model analisis kelayakan pemberian kredit mobil, neural network radial basis function digunakan:

##### Melatih dan Menguji Data Multi Layer Perceptron

```
from sklearn.neural_network import MLPClassifier
clf=MLPClassifier(hidden_layer_sizes=13, learning_rate_init=0.1, max_iter=100)

clf.fit(X_train, Y_train)

/usr/local/lib/python3.10/dist-packages/sklearn/neural_network/_multilayer_perceptron
warnings.warn(
    "The MLPClassifier is deprecated in favor of MLPClassifier.
    MLPClassifier(hidden_layer_sizes=13, learning_rate_init=0.1, max_iter=100)

from sklearn.metrics import accuracy_score, classification_report, confusion_matrix

Y_predict=clf.predict(X_test)
```

Gambar 5. Proses Pembelajaran Dengan Multilayer Perceptron

#### e. Visualisasi Confusion Matrix

Untuk mengukur ketepatan dan keakuratan model dilakukan pengujian dengan confusion matrix. Confusion Matrix berisi informasi tentang sistem klasifikasi, baik aktual maupun prediksi. Nilai confusion matrix, yang didasarkan pada model multilayer perceptron yang telah dilatih dengan data, ditunjukkan pada gambar 7 dibawah ini.

```
print('Confusion Matrix', confusion_matrix)

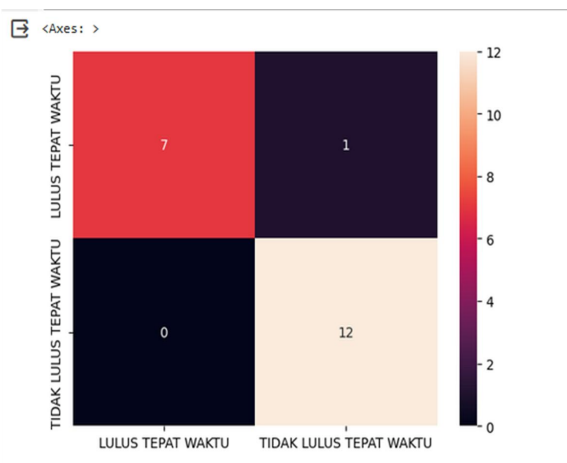
Confusion Matrix <function confusion_matrix at 0x7b9fc0229c60>

from sklearn.metrics import confusion_matrix

res = confusion_matrix(Y_test, Y_predict)

ses.heatmap(res, annot=True, xticklabels=["LULUS TEPAT WAKTU", "TIDAK LULUS TEPAT WAKTU"],

<Axes: >
```



Gambar 6. Hasil Pengujian Confusion Matrix



#### f. Hasil akurasi

Hasil perhitungan evaluasi Precision, Recall, dan F-Score dan akurasi model Multilayer Perceptron pada data training dapat dilihat pada gambar berikut.

```
print('Akurasi', accuracy_score(Y_test, Y_predict))
Akurasi 0.95

print('Hasil', classification_report(Y_test, Y_predict))
```

Hasil	precision	recall	f1-score	support
0.0	0.90	1.00	0.95	9
1.0	1.00	0.91	0.95	11
accuracy			0.95	20
macro avg	0.95	0.95	0.95	20
weighted avg	0.96	0.95	0.95	20

Gambar 7. Akurasi Dengan Multilayer Perceptron

Hasil prediksi menggunakan Algoritma Multilayer Perceptron menunjukkan bahwa prediksi berdasarkan gender, IPS, dan SKS semester 1-6, memiliki akurasi 82%. Percobaan dengan skenario 80:20 menghasilkan hasil akurasi 0.954.

#### 4. KESIMPULAN

Hasil perhitungan algoritma Multilayer Perceptron didapatkan beberapa kesimpulan sebagai berikut :

1. Data kelulusan mahasiswa berdasarkan gender, nilai IPS1-6, dan SKS 1-6 dapat diprediksi dengan menggunakan algoritma multilayer perceptron.
2. Pada proses keluaran hidden layer jika percobaan dilakukan beberapa kali secara acak selama proses pemilahan dan pengujian dataset, jumlah 3 hidden layer merupakan hasil yang baik untuk digunakan dalam prediksi.
3. Parameter learning rate = 0,01 dan jumlah iterasi/epoch = 100 Epoch dalam perhitungan Algoritma Multilayer perceptron dapat memberikan akurasi yang tinggi yaitu 95%.

#### REFERENSI

- [1] Amrin, A., & Satriadi, I. (2018). Implementasi Jaringan Syaraf Tiruan Dengan Multilayer Perceptron Untuk Analisa Pemberian Kredit. JURIKOM (Jurnal Riset Komputer), 5(6), 605-610.
- [2] Asmara, A., & Haryanto, H. (2015). Pengembangan tes minat dan bakat dengan metode jaringan syaraf tiruan (JST) untuk memprediksi potensi siswa bidang robotika. Jurnal Pendidikan Vokasi, 5(3), 273-286.
- [3] Bhakti, H. D. (2019). Aplikasi Artificial Neural Network (ANN) untuk Memprediksi Masa Studi Mahasiswa Program Studi Teknik Informatika Universitas Muhammadiyah Gresik. Jurnal Eksplorasi Informatika, 9(1), 88-95.
- [4] Hamdi, I., Budianita, E., Syafria, F., & Afrianty, I. (2023). Prediksi Jumlah Perceraian Menggunakan Metode Multilayer Perceptron. JURNAL MEDIA INFORMATIKA BUDIDARMA, 7(3), 1352-1361.
- [5] Id, I. D. (2021). Machine Learning: Teori, Studi Kasus dan Implementasi Menggunakan Python (Vol. 1). Unri Press.
- [6] Kahar, N., & Arironang, W. (2022). Implementasi Jaringan Syaraf Tiruan Dengan Algoritma Perceptron Dalam Penentuan Program Studi Mahasiswa Baru. JURNAL AKADEMIKA, 14(2), 74-80.

- [7] Khoirudin, K., Nurdiyah, D., & Wakhidah, N. (2019). Prediksi Penerimaan Mahasiswa Baru Dengan Multi Layer Perceptron. *Jurnal Pengembangan Rekayasa dan Teknologi*, 14(1), 1-4.
- [8] Kurniawan, A., & Silvanie, A. (2021). Prediksi Pasien Penyakit Jantung Menggunakan Jaringan Syaraf Tiruan Multi Layer Perceptron dan Python pada Basis Data Penyakit Jantung di Cleveland. *Jurnal Nasional Informatika (JUNIF)*, 2(1), 21-28.
- [9] Mukhtar, H., Rifaldo, M., Taufiq, R. M., & Rizki, Y. (2021). Peramalan Kedatangan Wisatawan Mancanegara Ke Indonesia Menurut Kebangsaan Perbulannya Menggunakan Metode Multilayer Perceptron. *Jurnal CoSciTech (Computer Science and Information Technology)*, 2(2), 113-119.
- [10] Nurachim, R. I. (2019). Pemilihan model prediksi indeks harga saham yang dikembangkan berdasarkan algoritma Support Vector Machine (SVM) atau Multilayer Perceptron (MLP) studi kasus: saham PT Telekomunikasi Indonesia Tbk. *Jurnal Teknologi Informatika dan Komputer*, 5(1), 29-35.
- [11] Ramadhan, A. F., & Saputra, R. A. (2023). Prediksi Jumlah Penumpang Bandar Udara Halo Oleo Kendari Menggunakan Multi-layer Perceptron. *JOINTER: Journal of Informatics Engineering*, 4(02), 33-38.
- [12] Ridwan, R., Lubis, H., & Kustanto, P. (2020). Implementasi algoritma neural network dalam memprediksi tingkat kelulusan mahasiswa. *Jurnal Media Informatika Budidarma*, 4(2), 286-293.
- [13] Romadhona, A., Suprapedi, S., & Himawan, H. (2017). Prediksi Kelulusan Mahasiswa Tepat Waktu Berdasarkan Usia, Jenis Kelamin, Dan Indeks Prestasi Menggunakan Algoritma Decision Tree. *Jurnal Cyberku*, 13(1), 8-8.
- [14] Rudianto, R., Kania, R., & Solihati, T. I. (2022). PREDIKSI KELULUSAN MAHASISWA TEKNIK INFORMATIKA UNIVERSITAS BANTEN JAYA MENGGUNAKAN ALGORITMA NEURAL NETWORK. *Jurnal Sistem Informasi dan Informatika (Simika)*, 5(2), 193-200.
- [15] Saad, M. I. S. (2023). Perbandingan Algoritma Extreme Learning Machine dan Multilayer Perceptron Dalam Prediksi Mahasiswa Drop Out. *Bulletin of Information Technology (BIT)*, 4(3), 369-376.
- [16] Shedriko, S. (2021, January). Single Layer Perceptron Dengan Backpropagation Dalam Memprediksi Kelulusan Mahasiswa Pada Mata Kuliah Pti Di Universitas Xyz. In *Semnas Ristik (Seminar Nasional Riset dan Inovasi Teknologi) (Vol. 5, No. 1)*.
- [17] Suhardjono, S., Wijaya, G., & Hamid, A. (2019). prediksi waktu kelulusan mahasiswa menggunakan SVM berbasis PSO. *Bianglala Informatika*, 7(2), 97-101.
- [18] Suleman, A. R., & Palupi, I. (2023). Penerapan Artificial Neural Network (ANN) untuk Prediksi Prestasi Akhir Mahasiswa Melalui Nilai Mata Kuliah Dasar Tingkat 1. *eProceedings of Engineering*, 10(2).
- [19] Thaniket, R., Kusri, K., & Luthf, E. T. (2020). Prediksi Kelulusan Mahasiswa Tepat Waktu Menggunakan Algoritma Support Vector Machine. *Jurnal FATEKSA: Jurnal Teknologi dan Rekayasa*, 5(2), 20-29.
- [20] R. Husna, Y. Hendra and M.I. Akbar (2019). Comparison Between Apriori and Fp-Growth Algorithms on Inventory Model of Item Availability. *J. Ipte. Terap.*, vol. 14, no. 3, pp. 219–229, 2020, doi: <https://doi.org/10.22216/jit.v14i3.100>.
- [21] Hendra, Y. Sakinah, P. Thoriq, M. (2023). Evaluasi Kinerja Algoritma Apriori Dalam Pengelompokan Data Transaksi Penjualan Untuk Analisis Pola Pembelian. *Journal of Student Development Information System (JoSDIS)* 3 (2), 220-228.