



## Implementasi Algoritma Neural Network dalam Memprediksi Tingkat Kelulusan Mahasiswa

Ridwan<sup>1</sup>, Hendarman Lubis<sup>2</sup>, Prio Kustanto<sup>2,\*</sup>

<sup>1</sup> Ilmu Komputer, STMIK Nusa Mandiri, Jakarta, Indonesia

<sup>2</sup> Teknik, Teknik Informatika, Universitas Bhayangkara Jakarta Raya, Jakarta, Indonesia

Email: <sup>1</sup>ridwans70@gmail.com, <sup>2</sup>hendarman.lubis@dsn.ubharajaya.ac.id, <sup>3,\*</sup>prio.kustanto@dsn.ubharajaya.ac.id

Email Penulis Korespondensi: prio.kustanto@dsn.ubharajaya.ac.id

**Abstrak**—Lembaga pendidikan tinggi dituntut untuk menjadi penyedia pendidikan yang berkualitas. Salah satu instrumen yang digunakan oleh pemerintah untuk mengukur kualitas penyedia pendidikan adalah jumlah lulusan. Semakin tinggi tingkat kelulusan, semakin baik kualitas pendidikan dan kualitas yang baik ini akan secara positif mempengaruhi nilai akreditasi yang diberikan oleh BAN-PT. Oleh karena itu, dalam penelitian ini peneliti memberikan masukan untuk penelitian yang dilakukan di Universitas Bhayangkara Jakarta Raya untuk memprediksi tingkat kelulusan siswa menggunakan algoritma *Neural Network*. *Neural Network* adalah salah satu metode dalam *machine learning* yang dikembangkan dari *Multi Layer Perceptron (MLP)* yang dirancang untuk memproses data dua dimensi. *Neural Network* termasuk dalam tipe *Deep Neural Network* karena dalamnya tingkat jaringan dan banyak diimplementasikan dalam data citra. *Neural Network* memiliki dua metode; yaitu klasifikasi menggunakan *feedforward* dan tahapan pembelajaran menggunakan *backpropagation*. Cara kerja *Neural Network* mirip dengan *MLP* tetapi di *Neural Network* setiap *neuron* disajikan dalam dua dimensi, tidak seperti *MLP* dimana masing-masing *neuron* hanya berukuran satu dimensi. Adapun akurasi prediksi yang diperoleh adalah 98,27%.

**Kata Kunci:** Tingkat Kelulusan, Neural Network, Multi Layer Perceptron, Backpropagation, Akurasi Prediksi

**Abstract**—Higher education institutions are demanded to be quality education providers. One of the instruments used by the government to measure the quality of education providers is the number of graduates. The higher the graduation level, the better the quality of education and this good quality will positively influence the value of accreditation given by BAN-PT. Therefore, in this study the researchers provided input for research conducted at Bhayangkara Jakarta Raya University to predict student graduation rates using the Neural Network algorithm. Neural Network is one method in machine learning developed from Multi Layer Perceptron (MLP) which is designed to process two-dimensional data. Neural Network is included in the Deep Neural Network type because of its deep network level and is widely implemented in image data. Neural Network has two methods; namely classification using feedforward and learning stages using backpropagation. The way Neural Network works is similar to MLP, but in Neural Network each neuron is presented in two dimensions, unlike MLP where each neuron is only one dimensional in size. The prediction accuracy obtained is 98.27%.

**Keywords:** Graduation Rate, Neural Network, Multi-Layer Perceptron, Backpropagation, Prediction Accuracy

### 1. PENDAHULUAN

Kelulusan siswa adalah salah satu tujuan strategis dari setiap penyedia pendidikan tinggi karena merupakan salah satu standar dalam instrumen penilaian akreditasi.

Universitas Bhayangkara Jakarta Raya, dalam hal ini Program Studi Manajemen Fakultas Ekonomi sangat memerlukan metode yang dapat memfasilitasi keinginan para pemangku kepentingan di Universitas Bhayangkara Jakarta Raya, sehingga kelulusan mahasiswa program studi manajemen dapat diprediksi sebelumnya.

Berdasarkan data yang diperoleh dari program studi manajemen, ada 185 siswa yang dinyatakan lulus dengan rata-rata lulusan lebih dari 4 tahun. Masa studi yang lebih dari 4 tahun pada tahun 2018 tentu saja dapat dipercepat jika pemangku kepentingan dalam hal ini pejabat di program studi manajemen dapat memprediksi kelulusan mahasiswa lebih awal. Akselerasi mahasiswa untuk dapat lulus tepat waktu tentu akan mendapatkan peringkat yang baik pada akreditasi program studi oleh BAN-PT [1].

Oleh karena itu, program studi manajemen perlu menerapkan metode yang tepat untuk menjawab masalah ini dengan menerapkan metode untuk memprediksi kelulusan mahasiswa. Sehingga masalah mahasiswa yang tidak lulus tepat waktu dapat dikurangi.

Terdapat beberapa penelitian sebelumnya yang dilakukan dengan menggunakan metode algoritma *neural network*, yaitu:

1. Penelitian yang dilakukan oleh Azahari dan Yulindawati dengan judul Perbandingan Algoritma *Data Mining Naive Bayes* dan *Neural Network* Dalam Memprediksi Masa Studi Mahasiswa. Penelitian ini menghasilkan akurasi 72,58% [2].
2. Penelitian dilakukan oleh Kusuma Dewi, Wing Wahyu Winarno, dan M. Rudyanto Arief dengan judul Prediksi Kelulusan Mahasiswa Menggunakan Metode Jaringan Saraf Tiruan dan *Particle Swarm Optimization*. Dalam penelitian ini, diperoleh nilai akurasi prediksi 87,31% [3].
3. Penelitian dilakukan oleh Abdul Rohman dan Muhammad Rochcham dengan judul Komparasi Metode Klasifikasi *Data Mining* Untuk Prediksi Kelulusan Mahasiswa. Dalam penelitian ini, ditemukan bahwa nilai akurasi prediksi kelulusan mahasiswa adalah 91,7% [4].

Dari ketiga penelitian di atas dilakukan pengujian dengan menerapkan *learning rate* yang menjauhi angka 0 dan mendekati angka 1. Dimana kita ketahui semakin besar nilai *learning rate*, proses *training* akan berjalan lebih cepat. Namun, jika nilai *learning rate* relatif terlalu besar, secara umum proses *training* dapat melebihi



keadaan optimal yaitu ketika nilai kesalahan minimum tercapai. Dengan kata lain, *learning rate* mempengaruhi keakuratan jaringan suatu sistem. Semakin besar nilai *learning rate*, akurasi jaringan akan menurun, tetapi sebaliknya, jika *learning rate* semakin kecil, maka akurasi jaringan akan semakin besar atau meningkat dengan konsekuensi bahwa proses *training* akan memakan waktu lebih lama [5].

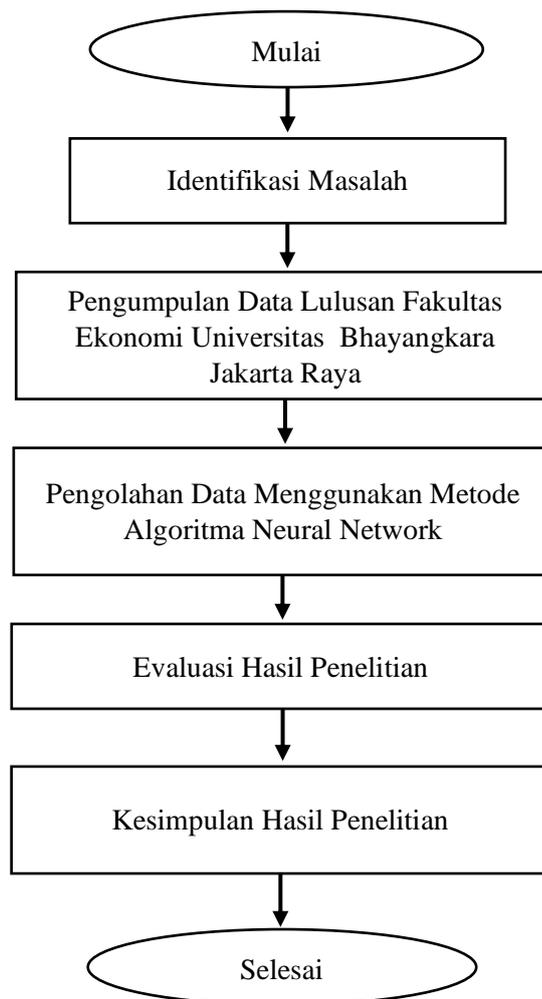
Masalah *learning rate* ini dapat diatasi dengan menerapkan sejumlah langkah dengan mengurangi jumlah atribut yang tidak penting dalam *dataset* penelitian. Pentingnya atribut dapat diukur dengan pengaruhnya terhadap akurasi dan presisi dan nilai AUC yang dihasilkan ketika *dataset* diolah dengan *Rapidminer* [6].

Penulis dalam hal ini telah menerapkan metode diatas dengan mengurangi beberapa atribut yang tidak dibutuhkan dan nilai absen yang tidak berpindah dari angka 0 ke 1.

## 2. METODE PENELITIAN

### 2.1 Tahapan Penelitian

Penelitian ini disusun melalui tahap tahap-tahap yang sistematis dengan tujuan agar penelitian menjadi terarah. Adapun tahap-tahap penelitian yang dilakukan adalah sebagai berikut.



**Gambar 1.** Tahapan Penelitian

### 2.2 Instrumen Penelitian

Instrumen penelitian merupakan alat yang digunakan dalam pengolahan data menjadi sebuah informasi yang bermanfaat. Adapun data yang digunakan dalam penelitian ini adalah data lulusan prodi manajemen Fakultas Ekonomi Universitas Bhayangkara Jakarta Raya angkatan tahun 2014 dan tahun 2015. Selanjutnya data tersebut diolah menggunakan aplikasi *Rapidminer Studio 9.3* untuk mengetahui akurasi dari prediksi tingkat kelulusan mahasiswa.

### 2.3 Teknik Pengumpulan Data



Metode pengumpulan data yang dilakukan pada penelitian ini adalah melakukan studi literatur terhadap data-data akademik yang menyangkut nilai dan SKS mahasiswa yang ada di Fakultas Ekonomi Universitas Bhayangkara Jakarta Raya.

## 2.3 Machine Learning

Di era popularitas sains, *machine learning* dapat dikatakan sebagai cabang dari disiplin ilmu *artificial intelligence* yang banyak digunakan oleh para praktisi bisnis dan akademik. Kemampuannya dalam pengembangan sistem berdasarkan data, membuat banyak orang menggunakannya sebagai metode dalam penelitian. Banyak hal yang dipelajari perlu dipelajari dalam *machine learning* tetapi pada dasarnya ada 4 hal utama yang perlu kita ketahui yaitu *Supervised Learning*, *Unsupervised Learning*, *Semi-supervised learning*, dan *Reinforcement Learning* [7]. Salah satu teknik untuk menerapkan *machine learning* adalah *supervised learning*. Seperti dibahas sebelumnya, *machine learning* tanpa data tidak akan berhasil. Karena itu, hal pertama yang disiapkan adalah data. Data biasanya akan dibagi menjadi 2 kelompok, yaitu data *training* dan data *testing*. Data *training* akan digunakan untuk melatih algoritma menemukan model yang cocok, sedangkan data *testing* akan digunakan untuk menguji dan menentukan kinerja model yang diperoleh pada tahap pengujian [8].

Dari model yang didapat, kita bisa membuat prediksi yang dibagi menjadi dua jenis, tergantung pada jenis *output*. Jika hasil prediksi terpisah, maka itu disebut proses klasifikasi. Misalnya klasifikasi *gender* dilihat dari tulisan tangan (*output* laki-laki dan perempuan). Sementara itu, jika *output*nya kontinu, itu disebut proses regresi. Misalnya prediksi kisaran harga rumah di kota Jakarta (*output* berupa harga rumah) [9].

## 2.3 Data Mining

*Data mining* adalah teknologi yang menggabungkan metode analisis tradisional dengan algoritma canggih untuk memproses volume data yang besar. *Data mining* adalah istilah yang digunakan untuk menemukan pengetahuan yang tersembunyi dalam *database*. *Data mining* adalah proses semi-otomatis yang menggunakan teknik statistik, matematika, intelegensia, dan *machine learning* untuk mengekstraksi dan mengidentifikasi informasi yang berguna dan berguna yang disimpan dalam *database* besar [10].

Beberapa definisi awal *data mining* berfokus pada olah data dalam proses otomatis. Teori tentang data mining banyak digunakan dalam bidang pemasaran, penjualan, dan *customer service* dengan tujuan yang sama yakni mendefinisikan *data mining* sebagai proses eksplorasi dan analisis data dalam jumlah besar secara otomatis dan semi-otomatis sehingga ditemukan pola atau aturan yang bermakna [11].

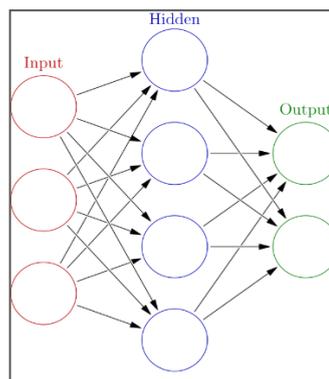
Analisis otomatis yang dilakukan oleh *data mining* melebihi yang dilakukan oleh sistem pendukung keputusan tradisional yang sudah banyak digunakan. *Data mining* dapat menjawab pertanyaan bisnis yang secara tradisional membutuhkan banyak waktu dan biaya tinggi. *Data mining* mengeksplorasi basis data untuk menemukan pola tersembunyi, mencari informasi untuk memprediksi apa yang mungkin dilupakan oleh para pelaku bisnis dan praktisi pendidikan karena letaknya di luar harapan mereka.

Pesatnya perkembangan dalam teknologi pemrosesan data telah memudahkan manusia untuk mengumpulkan sejumlah besar data, sehingga menghasilkan banyak data. *Data mining* adalah proses pencarian informasi secara otomatis yang berguna dalam penyimpanan data yang besar. Istilah lain yang sering digunakan termasuk penemuan pengetahuan (penambangan) di *database* (KDD) [12].

Istilah *data mining* dan *Knowledge Discovery in Database (KDD)* sering digunakan secara bergantian untuk menggambarkan proses penggalian informasi tersembunyi dalam database besar. Sebenarnya kedua istilah tersebut memiliki konsep yang berbeda, tetapi saling terkait satu sama lain. Dan salah satu tahapan dalam keseluruhan proses *KDD* adalah *data mining*.

## 2.4 Algoritma Neural Network

*Neural network* adalah model algoritmik yang terinspirasi oleh bagaimana *neuron* dalam otak manusia bekerja. Setiap *neuron* di otak manusia saling terhubung dan informasi mengalir dari masing-masing *neuron* tersebut [13].



Gambar 2. Model Neural Network



Adapun metode penelitian yang digunakan dalam penelitian ini meliputi metode pengumpulan data, dan metode algoritma *neural network* menggunakan data *training*, *learning*, maupun *testing* [14].

1. Metode Pengumpulan Data

Penelitian ini dilakukan dengan menggunakan data primer. Data primer tersebut berupa data mahasiswa angkatan 2014 dan 2015. Dari masing-masing data tersebut diambil data *testing* sebesar 50 %. Data tersebut terdiri dari beberapa atribut, yaitu NIM, IP Semester 1 sampai 4, SKS Semester 1 sampai 4, Rata-Rata IPK, dan SKS Total.

2. Metode Pengumpulan *Data Training*, *Learning*, dan *Testing* Menggunakan Algoritma *Neural Network*

Penelitian ini menggunakan *neural network* sebagai proses *training* dari hasil pengumpulan data. Dalam proses *training* data kelulusan mahasiswa akan diproses terlebih dahulu dengan mengubah nilai IPK menjadi angka 1 atau 0, Angka 1 didefinisikan lulus tepat waktu dan angka 0 tidak lulus tepat waktu. Dari hasil pengklasifikasian 0 dan 1 tersebut kemudian data *training* menggunakan *neural network*.

Proses *training* algoritma *neural network* memerlukan tiga tahap, yaitu *feedward* data *input* untuk *training*, *backpropagation* untuk nilai *error* serta penyesuaian nilai bobot tiap *node* masing-masing *layer* pada *Neural Network*. Diawali dengan *feedward* nilai *input*, tiap *input* unit ke-*i* ( $x_i$ ) menerima sinyal *input* yang selanjutnya akan dipancarkan ke *hidden layer*  $z_1, \dots, z_p$ . Selanjutnya *hidden* unit ke-*j* akan menghitung nilai sinyal ( $z_j$ ), yang akan dipancarkan ke *output layer*, menggunakan fungsi aktivasi *f*.

$$z_{in_j} = \theta_{1j} + \sum_{i=1}^n x_i v_j \tag{1}$$

Dan

$$z_j = f(z_j) \tag{2}$$

Dimana  $\theta_{1j}$  = bias *hidden* unit ke-*j*. Nilai bias dan bobot awal dapat diambil secara acak. Tiap unit *output* ke-*k* ( $Y_k$ ).

$$Y_k = \theta_{2k} + \sum_j z_k w_{jk} \tag{3}$$

dan

$$Y_k = f(Y_k) \tag{4}$$

Dimana  $\theta_{2k}$  = bias *hidden* unit ke-*k*. Selama proses *training* berlangsung, tiap unit *output* membandingkan nilai target ( $T_m$ ) untuk suatu *input pattern* guna menghitung nilai parameter yang akan memperbaiki (*update*) bobot nilai tiap unit dalam masing-masing *layer*.

### 3. HASIL DAN PEMBAHASAN

Prediksi kelulusan mahasiswa menggunakan algoritma *neural network* dilakukan dengan membagi dua data menjadi data *training* (angkatan 2014) dan data *testing* (angkatan 2015). Proses prediksi *neural network* dijalankan menggunakan aplikasi *Rapidminer Studio 9.3*

#### 3.1 Pengolahan Data dengan Metode *Neural Network*

Percobaan dilakukan dengan menggunakan *tools Rapidminer 9.3* dan metode algoritma *neural network*. Parameter yang ditampilkan berupa *training cycle*, *learning rate*, *momentum*, dan *hidden layer*. 0,1 untuk *learning rate* dan 0,1 untuk *momentum*. Hasil percobaan dapat dilihat pada tabel 1 dibawah ini.

**Tabel 1.** Percobaan Nilai *Training Cycle*

<i>Training Cycles</i>	<i>Learning Rate</i>	Momentum	Akurasi
200	0.1	0.1	98.19 %
400	0.1	0.1	98.19 %
600	0.1	0.1	98.27 %
800	0.1	0.1	97.90 %

Berdasarkan hasil percobaan diatas, dipilih nilai *training cycle* terbesar yaitu 600 dengan tingkat akurasi 98,27 %. Nilai ini selanjutnya digunakan untuk percobaan dalam menentukan *learning rate*.

Nilai dari *learning rate* didapatkan dengan memasukkan nilai dari *range* 0.1 sampai dengan 1. Sedangkan nilai 0.1 digunakan untuk nilai *momentum*. Hasil percobaannya dapat dilihat dari table 2 dibawah ini.



**Tabel 2.** Percobaan Penentuan *Learning Rate*

<i>Training Cycles</i>	<i>Learning Rate</i>	Momentum	Akurasi
600	0.1	0.1	98.27 %
600	0.5	0.1	97.83 %
600	0.7	0.1	97.83 %
600	1	0.1	97.80 %

Nilai *learning rate* dipilih berdasarkan nilai akurasi tertinggi yang dihasilkan. Berdasarkan percobaan tersebut nilai *learning rate* dengan akurasi tertinggi adalah 0.1. Selanjutnya nilai ini akan digunakan dalam menentukan nilai *momentum*. Nilai *momentum* ditentukan dengan cara memasukkan nilai dengan *range* 0 sampai dengan 0.9. Nilai *training cycle* dan *learning rate* dipilih dari percobaan sebelumnya yakni 600 dan 0.1. Hasil percobaannya dapat dilihat pada table 3 dibawah ini.

**Tabel 3.** Percobaan Penentuan Nilai *Momentum*

<i>Training Cycles</i>	<i>Learning Rate</i>	Momentum	Akurasi
600	0.1	0	98.27 %
600	0.1	0.3	97.83 %
600	0.1	0.7	97.83 %
600	0.1	0.9	97.80 %

Berdasarkan hasil percobaan diatas, maka parameter *neural network* dalam penelitian ini digunakan nilai 600 untuk *training cycle (epoch)*, 0.1 untuk *learning rate*, dan 0.1 untuk *momentum*.

Sementara untuk penentuan jumlah *hidden layer* dan *hidden node*, dilakukan uji coba dengan menggunakan satu dan dua *hidden layer*, sedangkan untuk *hidden node* menggunakan *range* nilai 1 sampai dengan 24. Hasil uji coba dapat dilihat pada table 4.

**Tabel 4.** Percobaan Satu Hidden Layer

Jumlah Hidden Node	Akurasi	Jumlah Hidden Node	Akurasi
3	98.27	14	97.94 %
7	97.93	17	97.94 %
9	97.91	21	97.94 %
13	97.94	24	97.94 %

Hasil percobaan terbaik adalah dengan satu hidden layer adalah dengan jumlah *hidden node* 3 dengan akurasi sebesar 98,27 %. Untuk dua *hidden layer*, dilakukan percobaan sebanyak 27 arsitektur. Hasil percobaan dapat dilihat pada table 5 dibawah ini.

**Tabel 5.** Percobaan dengan Dua *Hidden Layer*

Jumlah <i>Hidden Node Layer 1</i>	Jumlah <i>Hidden Node Layer 2</i>	Akurasi
1	1	97.94 %
1	3	97.94 %
1	5	97.94 %
1	7	97.94 %
1	9	97.94 %
2	1	96.91%
2	3	97.94 %
2	5	97.94 %
2	7	97.94 %
2	9	98.27 %
3	1	96.91 %
3	3	97.94%
3	5	97.94%
3	7	97.94%
3	9	97.94%

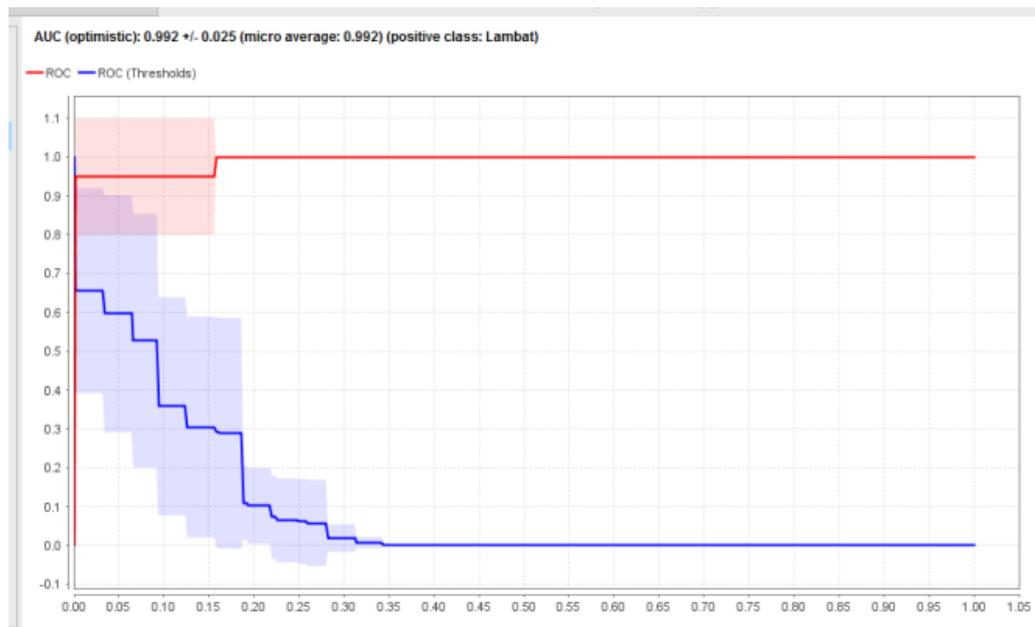


Berdasarkan hasil percobaan diatas untuk satu *hidden layer* dengan jumlah *hidden node* 3 tidak menghasilkan akurasi yang lebih baik dari 98,27 %. Adapun jumlah *input node* dalam penelitian ini ditentukan dengan cara melakukan percobaan sebanyak 2 kali. Yang pertama menggunakan 6 *input nodes* (Jenis Kelamin, IP1, SKS2, IP2, SKS3, IP3). Yang kedua menggunakan 8 *input nodes* (Jenis Kelamin, IP1, SKS2, SKS3, IP3, SKS4, IP4). Kedua percobaan diatas menggunakan parameter nilai 600 untuk *training cycle (epoch)*, 0.1 untuk *learning rate*, *hidden layer 1*, *hidden node 3*, dan 0.1 untuk *momentum*. Untuk *momentum* didapat hasil akurasi seperti pada table 6 dibawah ini.

**Tabel 6.** Percobaan Jumlah Input Node

Jumlah Input Node	Training Cycles (epoch)	Learning Rate	Momentum	Akurasi
4	600	0.1	0.1	96.90 %
6	600	0.1	0.1	97.96 %
8	600	0.1	0.1	98.27 %

Berdasarkan percobaan diatas jumlah *input nodes* 8 menghasilkan akurasi paling besar yaitu 98,27, maka pada penelitian menggunakan 8 *input nodes*. Proses *training* mendapatkan nilai *AUC (Area Under Curve)* sebesar 99,2 % yang dilihat dari gambar grafik *ROC* dibawah ini.



**Gambar 3.** Nilai AUC dalam Grafik ROC

Pengujian metode algoritma neural network dalam menentukan tingkat akurasi prediksi didapatkan confusion matrix melalui pengolahan 344 data yaitu :

Table View  Plot View

accuracy: 98.27% +/- 2.01% (micro average: 98.26%)

	true Cepat	true Lambat	class precision
pred. Cepat	317	5	98.45%
pred. Lambat	1	21	95.45%
class recall	99.69%	80.77%	

**Gambar 4.** Hasil Akurasi Prediksi

$$\begin{aligned}
 \text{Akurasi} &= \frac{(TN+TP)}{(TN+FN+TP+FP)} \\
 \text{Akurasi} &= \frac{(21+317)}{(21+1+317+5)} \\
 &= 0,982558
 \end{aligned}
 \tag{5}$$

Berdasarkan tabel 8 diatas diklasifikasikan sebagai berikut:



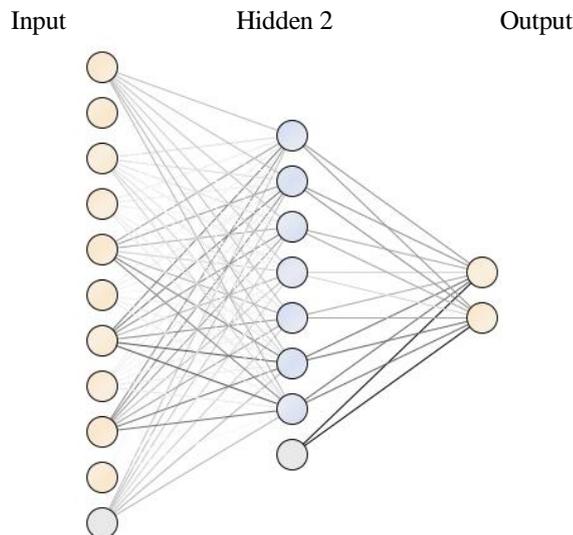
True Positive (TP) = 21 record

True Negative (TN) = 317 record

False Negative (FN) = 1 record

False Positive (FP) = 4 record

Adapun arsitektur *neural network* yang terbentuk dapat dilihat pada gambar 4 dibawah ini



**Gambar 5.** Arsitektur *Neural Network*

Berdasarkan hasil yang ditunjukkan diatas, disimpulkan bahwa penelitian ini menghasilkan akurasi prediksi kelulusan mahasiswa sebesar 98,27 %. Dengan nilai akurasi seperti itu, tentu sangat tepat untuk digunakan dalam membantu Fakultas Ekonomi, Universitas Bhayangkara Jakarta Raya dalam mengukur tingkat kelulusan mahasiswa.

#### 4. KESIMPULAN

Dari hasil penelitian yang dilakukan di Program Studi Manajemen Universitas Bhayangkara Jakarta Raya dapat diambil kesimpulan bahwa :

- 1) Hasil prediksi yang dihasilkan menunjukkan hasil yang menggambarkan bahwa kelulusan mahasiswa cenderung terlambat karena data training yang digunakan dominan memiliki tren terlambat.
- 2) Jumlah input seperti, input *nodes*, *training cycles*, *learning rate*, *momentum*, jumlah *hidden layer*, dan jumlah *hidden nodes* sangat mempengaruhi keakuratan algoritma *neural network*
- 3) Dari hasil penelitian yang dilakukan dan hasil penerapan algoritma *neural network*, parameter yang paling berpengaruh adalah IP (Indeks Prestasi) mahasiswa.
- 4) Hasil akurasi prediksi penerapan algoritma *neural network* terhadap prediksi kelulusan mahasiswa manajemen di Universitas Bhayangkara Jakarta Raya University dengan sampel angkatan 2014 dan 2015 sebesar 98,27%.

Dengan hasil yang diperoleh dari penelitian ini, keakuratan dapat ditingkatkan dengan mengurangi jumlah parameter dan meningkatkan jumlah *node input* dan *layer* dalam studi berikutnya. Diskusi dan penerapan model fitur yang komprehensif, diharapkan dapat meningkatkan nilai akurasi yang semakin mendekati angka 100% pada penelitian-penelitian selanjutnya.

#### REFERENCES

- [1] I. P. Fandy and F. Ardian, "Optimalisasi Neural Network dengan Particle Swarm Optimization Untuk Prediksi Kelulusan Mahasiswa," *Inform. dan RPL*, vol. 8, no. March, pp. 139–150, 2019.
- [2] A. Azahari, Y. Yulindawati, D. Rosita, and S. Mallala, "Komparasi Data Mining Naive Bayes dan Neural Network memprediksi Masa Studi Mahasiswa S1," *JTIK*, vol. 6, no. 6, p. 25126, 2019.
- [3] D. Kusumawati, W. W. Winarno, and M. R. Arief, "Prediksi Kelulusan Mahasiswa Menggunakan Metode Neural Network dan Particle Swarm Optimization," *SemnasTeknomedia Online*, vol. 3, no. 1, pp. 3–8–37, 2015.
- [4] M. Rohman, A., dan Rochcham, "Komparasi Metode Klasifikasi Data Mining Untuk Prediksi Kelulusan Mahasiswa," *J. Neo Tek.*, vol. 5, no. 1, 2019.
- [5] M. D. Yalidhan, "Implementasi Algoritma Backpropagation Untuk Memprediksi Kelulusan Mahasiswa," *Klik - Kumpul. J. Ilmu Komput.*, vol. 5, no. 2, p. 169, 2018.
- [6] A. N. Noor, "Prediksi Siswa Lulus Tidak Tepat Waktu Menggunakan Backpropagation Neural Network," *J. Hum. Teknol.*, vol. 3, no. 1, pp. 8–15, 2018.
- [7] D. Kartini, "Penerapan Data Mining dengan Algoritma Neural Network (Backpropagation) Untuk Prediksi Lama Studi



- Mahasiswa,” *Pros. Semin. Nas. Sisfotek*, vol. 3584, pp. 235–241, 2017.
- [8] U. T. Suryadi, “Komparasi Support Vector Machine dan Neural Network untuk Prediksi Kelulusan Sertifikasi Benih Kentang,” *Semin. Nas. Inform.*, vol. 1, no. 1, pp. 308–314, 2015.
- [9] M. Zainuddin, “Metode Klasifikasi Berbasis Particle Swarm Optimization (PSO) Untuk Prediksi Kelulusan Tepat Waktu Mahasiswa,” *J. Ilm. Teknol. Inf. Asia*, vol. 13, no. 1, p. 1, 2018.
- [10] R. Ansari, “Prediksi Kelulusan Mahasiswa dengan Jaringan Syaraf Tiruan,” *J. Teknol. Inf. Univ. Lambung Mangkurat*, vol. 1, no. 1, pp. 18–23, 2016.
- [11] Masrizal and H. Atma, “Prediksi Kelulusan Mahasiswa STMIK Dumai Menggunakan Jaringan Syaraf Tiruan,” *J. Inform.*, vol. 9, no. 2, pp. 9–14, 2017.
- [12] E. P. Rohmawan, “Prediksi Kelulusan Mahasiswa Tepat Waktu Menggunakan Metode Decision Tree dan Artificial Neural Network,” *J. Ilm. Matrik*, vol. 20, no. April, pp. 21–30, 2018.
- [13] U. Budiyanto and T. Fatimah, “Prediksi Kelulusan Tepat Waktu Mahasiswa Menggunakan Jaringan Syaraf Tiruan,” *SEMNASITIK*, pp. 152–160, 2019.
- [14] M. R. Lubis, “Metode Hybrid Particle Swarm Optimization - Neural Network Backpropagation Untuk Prediksi Hasil Pertandingan Sepak Bola,” *J-SAKTI (Jurnal Sains Komput. dan Inform.)*, vol. 1, no. 1, p. 71, 2017.