

## Analisis Jaringan Syaraf Tiruan dengan Backpropagation untuk Prediksi Mahasiswa Dropout

*Analysis of Artificial Neural Network with Backpropagation Algorithm for  
Prediction of Dropout Students*

Eka Yulia Sari\*<sup>1</sup>, Kusrini<sup>2</sup>, Andi Sunyoto<sup>3</sup>

<sup>1,2,3</sup> Universitas Amikom Yogyakarta

E-mail: \*[Ekasari2107@gmail.com](mailto:Ekasari2107@gmail.com), [Kusrini@amikom.ac.id](mailto:Kusrini@amikom.ac.id), [andi@amikom.ac.id](mailto:andi@amikom.ac.id)

### **Abstrak**

Universitas ABC Yogyakarta selalu melakukan evaluasi kinerja mahasiswa guna mengetahui pencapaian pada masing-masing mahasiswa. Mahasiswa yang melampaui masa studi dan tidak melakukan perpanjangan akan dikenakan sanksi berupa dropout. Kasus dropout tersebut dapat diminimalisir dengan pendeteksian secara dini terhadap mahasiswa yang beresiko dropout. Pendeteksian dapat dilakukan dengan memanfaatkan tumpukan data untuk memprediksi dropout mahasiswa. Pada penelitian ini bertujuan untuk memprediksi mahasiswa yang berpotensi dropout dengan masa studi maksimal yang harus diselesaikan pada jenjang Sarjana dengan mengimplementasikan Metode Backpropagation. Data yang digunakan dalam penelitian ini adalah data akademik prodi S1 Informatika Universitas ABC pada tahun 2016-2019 dengan jumlah dataset sebanyak 129. Tujuan penelitian ini untuk mengukur analisis prediksi dropout dengan percobaan penggunaan beberapa arsitektur jaringan. Hasil yang diperoleh dari model yang diusulkan yaitu model arsitektur 12-5-2 merupakan model arsitektur terbaik yang didapatkan. Learning rate terbaik sebesar 0,4 dengan momentum terbaik sebesar 0,95. Akurasi yang diperoleh dari prediksi mahasiswa dropout dengan arsitektur, learning rate, dan momentum terbaik sebesar 98,2%.

**Kata kunci**— Jaringan Syaraf Tiruan, Backpropagation, Prediksi, Dropout Mahasiswa

### **Abstract**

ABC University of Yogyakarta always evaluates student performance in order to find out the achievements of each student. Students who have exceeded the study period and not extended would be subject to sanctions in the form of a dropout. The dropout case can be minimized by early detection of students who are at risk of dropout. Detection can be done by utilizing a pile of data to predict student dropouts. In this study aims to predict students who have the potential to drop out with a maximum study period that must be completed at the Undergraduate level by implementing the Backpropagation Method. The data used in this study are academic data of S1 University Informatics Study Program of ABC University in 2016-2019 with the number of datasets as much as 129. The purpose of this study is to measure the dropout prediction analysis with the experiments of using several network architectures. The results obtained from the proposed model, namely architectural models 12-5-2, are the best architectural models obtained. The best learning rate is 0.4 with the best momentum of 0.95. The accuracy obtained from the prediction of dropout students is 98.2%.

**Keywords**— Neural Neural Network, Backpropagation, Prediction, Student Dropout

## 1. PENDAHULUAN

Universitas ABC Yogyakarta adalah salah satu universitas swasta di Yogyakarta yang sudah berdiri sejak lama. Pada Universitas ABC ada beberapa evaluasi mahasiswa setiap tahunnya untuk mengetahui pencapaian mahasiswa. Apabila pada tahun ke 2 tidak memenuhi syarat jumlah SKS < 40 dan IPK < 2.0 serta melampaui masa studi maksimal yang ditetapkan selama 4 tahun atau 8 semester dan tidak melakukan perpanjangan maka mahasiswa tersebut dinyatakan keluar atau DO (*dropout*). Pada Universitas ABC, banyak mahasiswa yang melampaui masa studi yang ditetapkan dan banyak yang tidak melakukan perpanjangan studi dikarenakan faktor tertentu. Untuk mengurangi kasus *dropout* mahasiswa yang tidak melakukan perpanjangan karena melebihi masa studi maksimal yang ditetapkan, maka perlu dilakukan pendeteksian. Pendeteksian secara dini atau pada tahun awal mahasiswa yang beresiko *dropout* sangat penting untuk menjaga mahasiswa dari *dropout* [1]. Deteksi mahasiswa beresiko *dropout* tersebut dapat membantu dalam pembuatan kebijakan universitas dalam mengarahkan dan mencegah atau meminimalisasi kasus *dropout*.

Kasus *dropout* sendiri merupakan suatu masalah bagi perguruan tinggi karena akan mempengaruhi akreditasi dan kualitas dari perguruan tinggi tersebut apabila tidak terkendali. Perolehan kualitas dalam sistem pendidikan tinggi harus direncanakan, dipantau, dan dikendalikan dalam setiap proses pendidikan dengan tujuan utama meningkatkan efisiensi siswa. Salah satu elemen penilaian akreditasi perguruan tinggi adalah lulus tepat waktu [2]. Adapun penyebab seorang mahasiswa gagal dalam menyelesaikan pendidikannya yaitu rendah dalam kemampuan akademik, faktor biaya, dan jarak domisili saat menempuh studi [3].

Pendeteksian dapat dilakukan dengan memanfaatkan data yang banyak pada database universitas ABC. Data tersebut sangat berpotensi memberikan informasi yang tidak terduga apabila diolah dengan benar. Kumpulan dari *record* data tersebut selalu bertambah setiap waktunya, jika tidak diolah dengan benar akan menjadi kumpulan data yang tidak berguna. Penggalan data akademik akan memberikan banyak informasi sehingga memberi suatu pengetahuan dan membantu dalam pengambilan keputusan oleh stakeholder terkait. Salah satu pemanfaatan data akademik mahasiswa yaitu untuk mencari dan memprediksi mahasiswa yang mempunyai kemungkinan mengalami *dropout* yang melebihi masa studi maksimal. Pemanfaatan *record* data disebut juga dengan *data mining*.

*Data mining* merupakan proses menemukan pengetahuan dalam database yang bersifat tersembunyi dengan proses semi otomatis serta penggunaan teknik statistik, matematika, kecerdasan buatan dan machine learning dalam mengekstrak serta mengidentifikasi sebuah informasi (pengetahuan) yang berpotensi dan bermanfaat [4]. *Data mining* dapat pula diartikan sebagai kombinasi secara logis antar pengetahuan data dan analisa statistika yang dikembangkan dalam pengetahuan bisnis atau proses yang memanfaatkan statistika, matematika, kecerdasan buatan dan machine learning guna mengekstraksi dan mengidentifikasi informasi yang berguna dan dapat dimanfaatkan bagi pengetahuan yang berkaitan dengan berbagai database yang besar [5]. Pekerjaan dalam data mining menurut Larose dapat dibagi menjadi 4 berdasarkan pekerjaan yang dilakukan diantaranya model prediksi, analisis kelompok, analisis asosiasi dan deteksi anomali [6]. Basis data yang telah tersimpan, tidak dapat mengenali pola-pola data tertentu yang diharapkan pada saat ini. Data dapat ditelusuri dan digunakan untuk membangun sebuah model yang digunakan untuk mengenali pola data yang diinginkan.

Pada penelitian sebelumnya, ada berapa algoritma klasifikasi yang digunakan untuk prediksi seperti yang dilakukan [7] menggunakan algoritma neural network (*Backpropagation*) untuk memprediksi lama studi mahasiswa. Dari penelitian tersebut dapat disimpulkan bahwa Jaringan Syaraf Tiruan (JST) *backpropagation* mampu memprediksi lama studi mahasiswa dengan variabel yang digunakan adalah variabel *gender*, index prestasi semester 1, jumlah pengambilan satuan kredit semester 2, index prestasi semester 2, jumlah pengambilan satuan kredit semester 3, jumlah pengambilan satuan kredit semester 4, index prestasi semester 4, jumlah pengambilan satuan kredit semester 5, dan index prestasi semester 5. Tingkat akurasi yang diperoleh dengan menggunakan algoritma neural network *backpropagation* sebesar 98,97%.

Penggunaan algoritma lain dalam memprediksi kelulusan mahasiswa juga dilakukan oleh [8]. Hasil yang diperoleh yaitu penggunaan atribut jenis kelamin dan agama tidak tepat sehingga mengurangi tingkat akurasi menjadi lebih rendah yaitu 50,77%. Pada penelitian [9] melakukan prediksi rentet waktu jangka pendek harga TBS berbasis algoritma backpropagation neural network yang menghasilkan tingkat rata-rata error yang terbaik dalam memprediksi dengan nilai RMSE terkecil yaitu 70,015.

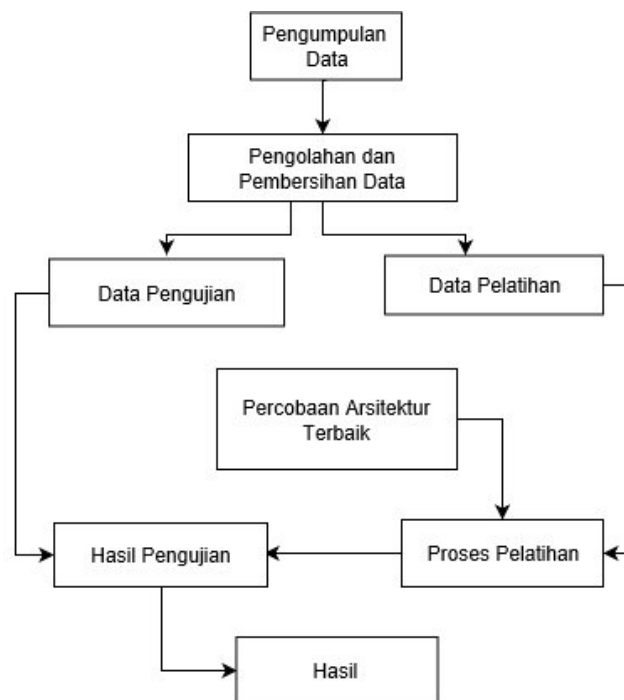
Berdasarkan uraian diatas, maka penelitian ini akan menganalisis prediksi dropout mahasiswa dengan Neural Network *backpropagation* untuk proses pengklasifikasiannya. Penggunaan JST yang didasari pada kemampuan belajar yang baik karena mampu dilatih untuk mempelajari dan menganalisa pola data dan mencari suatu formula atau fungsi yang dapat menghubungkan pola data masa lalu dengan keluaran yang diinginkan saat ini [10]. JST terdiri dari *input layer*, *hidden layer* dan *output layer*. Dimana *input layer* berfungsi untuk melakukan proses terhadap data masukan serta hasilnya disebarkan ke lapisan berikutnya. Keluaran dari *input layer* selanjutnya akan menjadi masukan bagi elemen pemrosesan pada lapisan *hidden layer*. Keluaran dari *hidden layer* ini yang akan menjadi keluaran jaringan syaraf tiruan yang mana diproses dahulu di lapisan tersembunyi.

Penelitian ini bertujuan untuk memprediksi mahasiswa yang beresiko *dropout* dengan menggunakan algoritma *backpropagation* untuk membantu pihak universitas ABC dalam pembuatan kebijakan. Pemilihan algoritma *backpropagation* berdasarkan pertimbangan bahwa algoritma ini mampu memecahkan masalah dunia nyata dengan membangun model terlatih dengan kinerja yang baik dalam beberapa masalah non-linier [11]. serta algoritma *backpropagation* mampu mengatasi pengenalan pola data yang sangat rumit [12].

## 2. METODE PENELITIAN

### 2.1. Tahap Penelitian

Tahap penelitian yang dilakukan terlihat pada Gambar 1 berikut.



Gambar.1 Tahap Penelitian

## a. Pengumpulan Data

Dalam penelitian ini digunakan dataset sekunder yang didapat dari bagian akademik universitas ABC. Dataset diambil berupa data akademik yang akan menjadi variabel input terdiri dari Data Indeks Prestasi Semester 1-4, Data jumlah matakuliah mengulang semester 1-4, Data jumlah presensi semester 1-4 tahun 2016 sampai 2019. Sedangkan variabel *output* adalah status mahasiswa yaitu *dropout* dan tidak *dropout*. Data diambil dari data akademik mahasiswa prodi informatika universitas ABC tahun 2016-2019.

## b. Pengolahan dan Pembersihan Data

Sebelum data digunakan untuk prediksi mahasiswa dropout, maka perlu dilakukan proses pembersihan data atau *cleaning data*. *Cleaning data* merupakan penghapusan data yang tidak konsisten, data yang kurang lengkap, dan data ganjil. Setelah proses *cleaning data*, proses selanjutnya yaitu perubahan data menjadi data kategorikal agar akurasi meningkat. Perubahan ke dalam data kategorikal juga dapat menambah efisiensi dari algoritma yang digunakan. Data murni yang berasal dari database tentunya mempunyai size yang besar, sehingga data yang digunakan hanya sebagian saja untuk mengurangi proses komputasi dalam pelatihan data. Pengambilan sebagian data dilakukan dengan tahap data *resize reduction* untuk memperoleh dataset dengan jumlah atribut dan record sesuai jumlah yang akan digunakan, namun tetap informatif.

Setelah data sudah melalui proses *cleaning*, data dinormalisasikan dengan persamaan 1. Penyesuaian range data dengan logsigmoid threshold function dalam metode *backpropagation* dilakukan dengan normalisasi ini [5].

$$x' = \frac{0,8(x-b)}{a-b} + 0,1 \quad (1)$$

Keterangan:

X' = Normalisasi data

X = Data sebelum dinormalisasi

a = Nilai maksimum data sebelum dinormalisasi

b = Nilai minimum data sebelum dinormalisasi.

Data perlu dilakukan normalisasi untuk menghindari dominasi dari variabel yang bernilai besar terhadap variabel bernilai kecil. Variabel yang digunakan dalam penelitian terlihat pada Tabel 1.

Tabel 1. Sampel Normalisasi Data Training

K_M	IPS1	IPS2	IPS3	IPS4	M1	M2	M3	M4	A1	A2	A3	A4	Status
M001	0,58	0,49	0,60	0,42	0,39	0,39	0,39	0,39	0,90	0,64	0,90	0,90	0,24
M002	0,63	0,36	0,55	0,59	0,39	0,64	0,39	0,39	0,64	0,90	0,90	0,64	0,46
M003	0,50	0,23	0,52	0,34	0,39	0,64	0,39	0,64	0,90	0,90	0,90	0,90	0,46
M004	0,55	0,47	0,62	0,68	0,39	0,39	0,39	0,13	0,64	0,90	0,90	0,39	0,24
M005	0,39	0,28	0,57	0,34	0,64	0,64	0,39	0,64	0,64	0,90	0,64	0,90	0,46
M006	0,48	0,29	0,36	0,38	0,39	0,64	0,64	0,64	0,39	0,90	0,90	0,90	0,46
M007	0,47	0,27	0,45	0,55	0,39	0,64	0,39	0,39	0,39	0,90	0,64	0,64	0,46
M008	0,63	0,53	0,64	0,75	0,39	0,39	0,13	0,13	0,39	0,64	0,64	0,39	0,24
M009	0,55	0,38	0,54	0,49	0,39	0,64	0,39	0,39	0,13	0,64	0,13	0,39	0,46
M010	0,64	0,67	0,77	0,83	0,39	0,39	0,39	0,13	0,90	0,90	0,90	0,90	0,24

Keterangan:

- IPS1 = Indeks Prestasi Semester 1  
 IPS2 = Indeks Prestasi Semester 2  
 IPS3 = Indeks Prestasi Semester 3  
 IPS4 = Indeks Prestasi Semester 4  
 M1 = Jumlah Matakuliah Mengulang Semester 1  
 M2 = Jumlah Matakuliah Mengulang Semester 2  
 M3 = Jumlah Matakuliah Mengulang Semester 3  
 M4 = Jumlah Matakuliah Mengulang Semester 4  
 A1 = Jumlah Absensi Semester 1  
 A2 = Jumlah Absensi Semester 2  
 A3 = Jumlah Absensi Semester 3  
 A4 = Jumlah Absensi Semester 4

a. Data Pelatihan dan Data Pengujian

Setelah dilakukan proses *data cleaning*, selanjutnya membagi data menjadi 2 yaitu data latih dan data uji. Data pelatihan yang digunakan sebanyak 20 dan data pengujian sebanyak 109.

b. Pelatihan dan Pengujian

Penelitian ini menggunakan metode klasifikasi dengan jaringan syaraf tiruan *backpropagation* untuk proses pelatihan data dan pengujian data. Awalnya, pencarian model arsitektur terbaik dilakukan dengan beberapa percobaan pada data latih dengan 10 model arsitektur *neural network*. Setelah model arsitektur terbaik didapatkan, selanjutnya dilakukan percobaan dengan beberapa perubahan *learning rate* dan momentum untuk mencari akurasi tertinggi dalam melatih data latih. Dalam pembelajaran metode *neural network backpropagation* terdapat beberapa tahapan yaitu [13]:

Langkah 0 : Bobot dari semua lapisan diinisialisasi dengan bilangan acak.

Langkah 1 : Jika kondisi penghentian belum terpenuhi, maka dilakukan langkah 2 sampai dengan 9

Langkah 2 : Untuk setiap pasang data pelatihan, lakukan langkah 3 sampai dengan 8

1. Fase I : Propagasi Maju

Langkah 3: Tiap unit masukkan menerima sinyal dan meneruskannya ke unit tersembunyi.

Langkah 4: Hitung semua keluaran di unit tersembunyi  $Z_j(j=1,2,\dots,p)$  dengan persamaan 1.

$$Z_{netj} = V_{j0} + \sum_{i=1}^p X_i V_{ji} \quad (1)$$

Langkah 5: Hitung semua jaringan di unit keluaran ( $Y_k$ ) dengan persamaan 2

$$Z_{netk} = V_{k0} + \sum_{i=1}^p Z_i V_{kj} \quad (2)$$

2. Fase II : Propagasi Mundur

Langkah 6 : hitung faktor  $\delta$  unit keluaran berdasarkan kesalahan di setiap unit keluaran  $Y_k(k=1,2,\dots,m)$  dengan persamaan 3

$$\delta_k = (t_k - y_k) f'(y_{netk}) = (t_k - y_k) y_k (1 - y_k) \quad (3)$$

Langkah 7: Hitung penjumlahan kesalahan dari unit tersembunyi ( $=\delta$ ) dengan persamaan 4

$$\delta_{netj} = \sum_{k=1}^m \delta_k W_{kj} \quad (4)$$

### 3. Fase III : Perubahan Bobot

Langkah 8: Hitung semua perubahan bobot. Perubahan bobot unit keluaran dengan persamaan 5:

$$W_{kj}(\text{baru}) = W_{kj}(\text{lama}) + \Delta W_{kj} \quad (5)$$

Dengan persamaan 6, dihitung Perubahan bobot unit tersembunyi:

$$V_{ji}(\text{baru}) = V_{ji}(\text{lama}) + \Delta V_{ji} \quad (6)$$

#### c. Hasil

Setelah dilakukan pelatihan dan pengujian, selanjutnya hasil didapatkan dari prediksi data uji dengan menghitung akurasi prediksi menggunakan *confusion matrix* dengan perintah plot confusion pada matlab. Evaluasi model klasifikasi didasarkan pada pengujian untuk memperkirakan obyek yang benar dan salah [14]. Pentabulasian urutan pengujian dalam confusion matrix yaitu kelas yang diprediksi ditampilkan dibagian atas matriks serta kelas yang diprediksi ditampilkan disisi kiri matrik. Setiap sel matrik berisi angka yang menunjukkan jumlah kasus sebenarnya dari kelas yang diprediksi [15].

## 3. HASIL DAN PEMBAHASAN

### 3.1. Parameter Jaringan

Untuk mendapatkan hasil yang sesuai dengan yang diinginkan harus melewati proses pelatihan dan pengujian dengan parameter-parameter yang sudah ditentukan sebelumnya [16]. Untuk menginisialisasi parameter-parameter JST *backpropagation* dengan menggunakan matlab dapat terlihat pada query berikut:

```
%Memberikan Parameter untuk mempengaruhi proses pelatihan
net.performFcn = 'mse';
net.trainParam.goal = 0.001;
net.trainParam.show = 20;
net.trainParam.epochs = 1000;
net.trainParam.mc = 0.95;
net.trainParam.lr = 0.1;
```


### 3.2. Arsitektur Jaringan

Untuk menghasilkan nilai output yang lebih akurat dalam menentukan hasil prediksi, diperlukan beberapa model arsitektur backpropagation [17]. Tingkat akurasi yang didapatkan akan optimal dengan dipengaruhi oleh pemilihan model arsitektur [18] [19]. Dalam penelitian ini, dilakukan percobaan arsitektur jaringan untuk menentukan arsitektur terbaik yang akan digunakan dalam prediksi data uji. Penggunaan parameter untuk percobaan pencarian model arsitektur terbaik yaitu: *Learning rate* 0,1 , Maksimal Epoch sebesar 1000, Parameter goal 0,001, dan momentum 0,95. Pada tabel 1 berikut akan di tampilkan arsitektur jaringan, nilai MSE dan akurasi yang didapatkan.

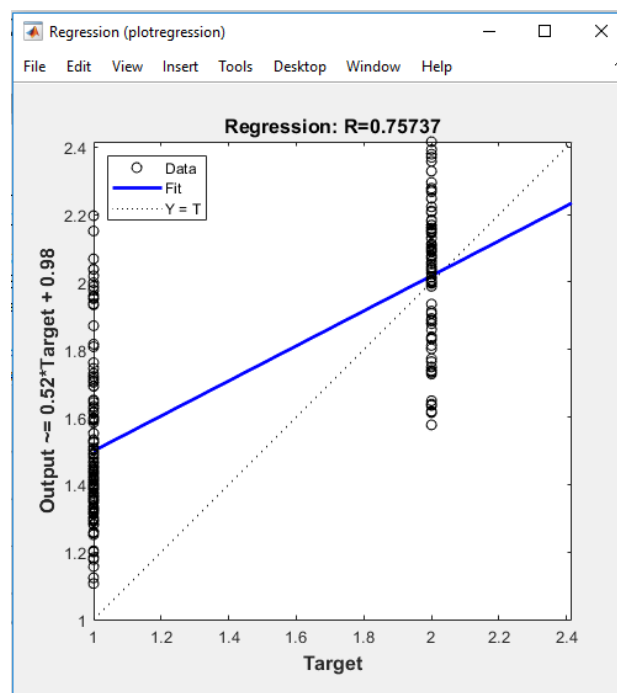
Tabel 1. Percobaan Arsitektur Jaringan

No	Asitektur	Training		
		Epoch	MSE	Akurasi
1	12-5-2	997	0,00784	90%
2	12-10-2	1000	0,00681	85%
3	12-15-2	1000	0,00722	70%
4	12-20-2	1000	0,00673	75%
5	12-25-2	1000	0,00572	70%

Dilakukan percobaan menggunakan beberapa arsitektur yaitu 12-5-2;12-10-2;12-15-2;12-15-2;12-20-2; dan 12-25-2. Selanjutnya menghitung Epoch, MSE dan akurasi pada masing-masing arsitektur untuk data pelatihan. Akurasi didapatkan dari hasil pelatihan data latih yang berjumlah 20 record data dengan plotconfusion pada matlab. Dari hasil percobaan 10 arsitektur, model 12-5-2 merupakan model arsitektur terbaik. Model arsitektur 12-5-2 mempunyai tingkat akurasi sebesar 95%.



Gambar 2. Hasil Best Training Performance Arsitektur 12-5-2



Gambar 3. HasilPerhitungan Regresi Arsitektur 12-5-2

Pada gambar 2 dan 3 memperlihatkan hasil data training dengan model arsitektur 12-5-2 yang diperoleh menggunakan MATLAB. Dari Gambar 2, terlihat epoch pada arsitektur 12-5-2 yaitu 997 dan nilai MSE sebesar 0,0075388. Pada gambar 3 terlihat bahwa regresi yang didapat pada arsitektur 12-5-2 sebesar 0,75737.

### 3.3. Learning Rate

Percobaan selanjutnya dengan mengubah *learning rate* karena perubahan parameter *learning rate* (pembelajaran) akan mempengaruhi hasil prediksi [19]. Pengujian dilakukan dengan model arsitektur 12-5-2 serta parameter maksimal epoch sebesar 5000, parameter goal 0,001 dan momentum 0,95.

Tabel 2. Pengujian *Learning Rate*

<i>Learning Rate</i>	Akurasi	Iterasi	Waktu
0,1	94,50%	4998 Iterasi	0:00:12
0,2	89,90%	4994 Iterasi	0:00:07
0,3	91,70%	4995 Iterasi	0:00:07
0,4	99,10%	4997 Iterasi	0:00:07
0,5	98,20%	5000 Iterasi	0:00:00


Pada Tabel 2 terlihat bahwa penggunaan *learning rate* 0,4 mendapatkan akurasi tertinggi sebesar 99,1%. Epoch yang dilakukan sebesar 4996 iterasi dengan waktu 00:00:07. Dari Tabel 2 terlihat jika *learning rate* bernilai tinggi maka akan semakin mempercepat waktu proses prediksi.

Tabel 3. Sample Hasil Prediksi dengan Arsitektur 12-5-2


IPS1	IPS2	IPS3	IPS3	M1	M2	M3	M4	K1	K2	K3	K4	target	Hasil
.....	.....	.....	.....	.....	.....	.....	.....	.....	.....	.....	.....	.....	.....
0,46	0,29	0,61	0,36	0,39	0,64	0,39	0,64	0,90	0,90	0,90	0,90	dropout	T
0,50	0,55	0,53	0,66	0,39	0,39	0,39	0,64	0,39	0,13	0,13	0,39	Tidak Dropout	Y
0,57	0,57	0,76	0,64	0,39	0,39	0,13	0,13	0,39	0,39	0,13	0,13	Tidak Dropout	T
0,52	0,26	0,30	0,29	0,39	0,64	0,64	0,64	0,64	0,90	0,64	0,90	dropout	Y
0,40	0,55	0,37	0,39	0,64	0,39	0,64	0,64	0,90	0,90	0,64	0,64	dropout	Y
0,81	0,75	0,59	0,64	0,13	0,13	0,39	0,13	0,39	0,13	0,90	0,39	Tidak Dropout	Y
0,71	0,76	0,81	0,78	0,39	0,13	0,13	0,13	0,64	0,39	0,39	0,13	Tidak Dropout	Y

Pada Tabel 3, menampilkan hasil prediksi data uji dengan menggunakan hidden layer, model arsitektur dan *learning rate* terbaik, untuk momentum yang digunakan sebesar 0,95. setelah mendapatkan model arsitektur dan *learning rate* yang optimal, selanjutnya digunakan untuk memprediksi data uji dengan jumlah 109 data prediksi. Akurasi hasil prediksi dihitung dengan confusion matrix yaitu dengan menghitung recall, precision, akurasi dan error rate. Untuk mengetahui pengaruh perubahan momentum, maka akan dilakukan percobaan perubahan momentum dengan hasil yang terlihat pada Gambar 4 dan 5.





Gambar 4. Hasil Confusion Matrix Momentum Sebesar 0,95



Gambar 5. Hasil Confusion Matrix Momentum Sebesar 0,80

Pada Gambar 5 dan 6 dapat dilihat bahwa perubahan momentum akan mempengaruhi akurasi prediksi. Pada percobaan perubahan momentum yaitu 0,95 dan 0,80, terlihat bahwa dengan 0,95 memiliki akurasi sebesar 98,2%. Hasil tersebut dilakukan dengan model arsitektur 12-5-2 dan parameter learning rate 0,4.

#### 4. KESIMPULAN

Berdasarkan pembahasan sebelumnya diperoleh hasil dan kesimpulan bahwa dari 5 model arsitektur yang diusulkan yaitu 12-5-2;12-10-2;12-15-2;12-15-2;12-20-2; dan 12-25-2, model arsitektur 12-5-2 memperoleh tingkat akurasi tertinggi. Sehingga 12-5-2 merupakan model arsitektur terbaik dalam memprediksi dropout mahasiswa berdasarkan indeks prestasi, keaktifan dan jumlah mata kuliah mengulang. Disimpulkan pula bahwa percobaan perubahan learning rate dan momentum akan mempengaruhi nilai akurasi yang didapat. Untuk learning rate, jika learning rate semakin tinggi akan mempengaruhi waktu proses yang dilakukan semakin cepat. Hasil prediksi dropout mahasiswa memperoleh akurasi sebesar 98,2% dengan menggunakan metode klasifikasi jaringan syaraf tiruan backpropagation. Prediksi yang dilakukan dengan 12 variabel yang terdiri dari : Indeks prestasi Semester 1, Indeks prestasi Semester 2, Indeks prestasi Semester 3, Indeks prestasi Semester 4, Pengulangan Matakuliah semester 1, pengulangan matakuliah semester 2, pengulangan matakuliah semester 3, pengulangan matakuliah semester 4, Presensi semester 1, presensi semester 2, presensi semester 3 dan presensi semester 4.

#### 5. SARAN

Pada penelitian selanjutnya, dapat dilakukan dengan penambahan algoritma optimasi dan juga penambahan variabel lain untuk meningkatkan akurasi prediksi yang didapatkan.

#### DAFTAR PUSTAKA

- [1] Deker, G. W., Pechenizkiy, M., Vleeshouwers, J. M., 2009, Predicting Students Drop Out: A Case Study, Educational Data Mining - EDM 2009, Cordoba, 1-3 Juli
- [2] Rohmawan, E. P., 2018, Prediksi Kelulusan Mahasiswa Tepat Waktu Menggunakan Metode Decision Tree dan Artificial Neural Network, Jurnal Ilmiah Matrik, No.1, Vol.20, Hal. 21-30.
- [3] Wijaya, I. H., 2017, Prediksi Mahasiswa Drop Out Berdasarkan Klasifikasi Administratif, Skripsi, Program Sarjana Sistem Informasi, Univ. Nusantara PGRI Kediri, Kediri
- [4] Turban, E., Rainer, K., Potter, R., 2005, Introduction to Information Technology, 3rd Edition, Willey, New Jersey.
- [5] Khusniyah, T. W., Sutikno., 2016, Prediksi Nilai Tukar Petani Menggunakan Jaringan Syaraf Tiruan Backpropagation, Scientific Journal of Informatics, vol. 3, no. 1, pp. 11– 18.
- [6] Kusri., Luthfi, E. T., 2009, ALGORITMA DATA MINING, Penerbit Andi, Yogyakarta.
- [7] Yalidhan, M. D., Amin, M. F., 2018, Implementasi Algoritma Backpropagation Untuk Memprediksi Kelulusan Mahasiswa, Kumpulan Jurnal Ilmu Komputer (KLIK), No.2, Vol. 05, Hal. 169-178.
- [8] Saragih, A. S., Saputra, A. C., 2017, Rancangan Bangun Sistem Prediksi Kelulusan Mahasiswa Jurusan Teknik Informatika Universitas Palangkaraya, Jurnal Teknologi Informatika, No.2, Vol.11,

- 
- [9] Puspitasari, D. I., Syukur, A., Supriyanto, C., 2015, Prediksi Rentet Waktu Jangka Pendek Harga TBS Berbasis Algoritma Backpropagation Neural Network, *JUSITI*, Vol. 4, No.1, Hal. 64-75
- [10] Laila, S. L., Agus, B., 2012, Pemodelan Jaringan Syaraf Tiran Untuk Memprediksi Awal Musim Hujan Berdasarkan Suhu Permukaan Laut, *Jurnal Ilmu Komputer Agri-Informatika*, No. 2, Vol.1, Hal. 52-61
- [11] Park, T.S., Lee, J. H., Choi, B., Optimization for Artificial Neural Network with Adaptive inertial weight of particle swarm optimization, 2009 8th IEEE International Conference, Hong Kong, Juni 15-17
- [12] Nikwntari, N., Kurniawan, H., Ritha. N., Kurniawan, D., K, 2018, Optimasi Jaringan Syaraf Tiruan Backpropagation Dengan Particle Swarm Optimization untuk Prediksi Pasang Surut Air Laut, *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, Vol.5, No.5, Hal. 605-612
- [13] Wanto, A., 2017, Optimasi Prediksi Denga Algoritma Backpropagation dan Conjugate Gradient Beale-Powel Restarts, *Jurnal Nasional Teknologi dan Sistem Informasi*. Vol. 03, No. 03, Hal. 370-380.
- [14] Gorunescu, F., 2011, *Data Mining: Concepts, Model and Techniques*, Kacprzyk, J., Jain, L. C., Springer, New York.
- [15] Hastuti, K., 2012, Analisis Komparasi Algoritma Klasifikasi Data Mining Untuk Prediksi Mahasiswa Non Aktif, *Seminar Nasional Teknologi & Komunikasi Terapan*, No. 1, Vol. 2, Hal. 241-249
- [16] Pratama, R. A., Anifah, L., 2016, Peramalan Beban Listrik Jangka Panjang Provinsi D.I. Yogyakarta Menggunakan Neural Network Backpropagation, *Jurnal Teknik Elektro*, vol. 5, no. 3, Hal. 37-47
- [17] Lubis, M. R., 2018, Analisis Jaringan Syaraf Tiruan Backpropagation Untuk Peningkatan akurasi prediksi Hasil Pertandingan Sepakbola, *TECHSI Jurnal*, Vol.10, No.1, Hal. 51-62.
- [18] Purba, I. S., Wanto, A., 2018, Prediksi Jumlah Nilai Impor Sumatra Utara Menurut Negara Asal Menggunakan Algoritma Backpropagation, *Techno.Com*, Vol.17, N0.3, Hal. 302-311,
- [19] Handayani, L., Adri, M., 2015, Penerapan JST (Backpropagation) Untuk Prediksi Curah Hujan, *Seminar Nasional Teknologi Informasi, Komunikasi dan Industri (SNTIKI)*, Pekanbaru, 11 November.
-