

JARINGAN SYARAF TIRUAN DENGAN METODE BACKPROPAGATION UNTUK MEMPREDIKSI JUMLAH MAHASISWA BARU

Lina Nurhani¹⁾, Aris Gunaryati,²⁾ Septi Andryana³⁾, Iskandar Fitri⁴⁾

¹⁾ Fakultas Teknologi Komunikasi dan Informatika Universitas Nasional
Jl. Sawo Manila No. 61, Pasar Minggu, Jakarta Selatan, 12520

Email : linanurhani64@gmail.com¹⁾, aris.gunaryati@civitas.unas.ac.id²⁾, septi.andryana@civitas.unas.ac.id³⁾,
tektel2001@yahoo.com⁴⁾

Abstrak

Jaringan syaraf tiruan merupakan program komputer yang dapat meniru proses pemikiran dan pengetahuan untuk menyelesaikan suatu masalah yang spesifik keputusan dapat diberikan secara cerdas. Algoritma Backpropagation merupakan salah satu algoritma jaringan syaraf tiruan yang sering digunakan dalam menyelesaikan masalah-masalah rumit karena memiliki tingkat akurasi yang baik. Hasil dari penelitian ini menunjukkan bahwa backpropagation memiliki tingkat akurasi yang baik dalam prediksi mahasiswa baru dengan struktur neuron 5-1 dengan 1 (satu) hidden layer, learning rate (lr) yang digunakan 0,1 dan nilai MSE 0,001. Pengujian dihentikan pada epoch ke 758, karena fungsi kinerja tujuannya sudah tercapai ($MSE = 0,000998685 < 0,001$) menunjukkan hubungan antara target dengan output jaringan pada saat pengujian sudah baik. Dari pengujian pada data pengujian antara output jaringan diperoleh target koefisien korelasi (R) bernilai 0,98779 dimana untuk hasil terbaik adalah bernilai 1.

Kata kunci: Akurasi, Backpropagation, Jaringan syaraf tiruan, prediksi, sistem cerdas

1. Pendahuluan

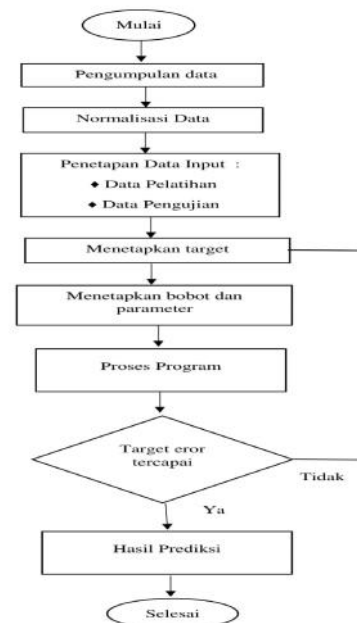
Jaringan Syaraf Tiruan merupakan salah satu representasi buatan dari otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran otak manusia tersebut [1]. Dalam ilmu komputer, jaringan syaraf tiruan banyak digunakan untuk menyelesaikan permasalahan yang berhubungan dengan peramalan atau prediksi [2]. Backpropagation merupakan salah satu metode dalam jaringan syaraf tiruan yang dapat diaplikasikan dengan baik dalam bidang peramalan (Forecasting) [3]. Setiap tahunnya jumlah mahasiswa baru di Universitas Nasional mengalami peningkatan, sehingga jumlah mahasiswa baru perlu diprediksi dengan cepat dan akurat agar pihak universitas dapat mengetahui perkiraan jumlah mahasiswa pertahunnya. Hal ini bermanfaat bagi Universitas Nasional dalam mengelola dan mengatur

sumber daya material dan dasar perencanaan serta keputusan bagi pimpinan universitas.

Metode yang digunakan untuk memprediksi adalah metode backpropagation. Metode backpropagation merupakan algoritma pembelajaran yang terawasi dan biasanya digunakan perceptron dengan banyak lapisan untuk mengubah bobot-bobot yang berhubungan dengan neuron-neuron yang ada pada lapisan tersembunyinya [4]. Dalam penelitian ini diharapkan metode Backpropagation dapat memprediksi jumlah mahasiswa baru dengan hasil error yang lebih kecil. Semakin kecil MSE, berarti jaringan syaraf tiruan semakin kecil kesalahannya dalam memprediksi jumlah mahasiswa baru. Adapun rumusan masalah dalam penelitian ini yaitu melakukan pelatihan dan pengujian pada jaringan syaraf tiruan dengan menggunakan software MATLAB 2017a. untuk data jumlah mahasiswa baru pada tahun 2014 sampai 2017 dan diprediksi berdasarkan fakultas.


2. Pembahasan

Dalam penelitian ini menggunakan kerangka penelitian seperti flowchar pada Gambar 1 berikut ini:



Gambar 1. Flowchart Kerangka penelitian

Model jaringan syaraf tiruan yang digunakan seperti pada Gambar 2 berikut ini:



Gambar 2. Model Jaringan Syaraf Tiruan

Pada gambar 2, X_1 hingga X_m merupakan unit masukan ke-1 hingga ke-m. Pada hidden layer atau synaptic weights, ada 5 unit tersembunyi, yaitu w_1 hingga w_m , sedangkan pada output-layer, hanya terdiri atas sebuah unit keluaran (output neuron), yaitu Y .

Prosedur pemodelan dengan ANN (Artificial Neural Network) secara umum terdiri dari empat langkah yaitu penyiapan data, pemilihan arsitektur, pembelajaran (learning), dan pengujian (testing).

Metode Backpropagation (Perambatan alat mundur) adalah sebuah metode sistematis untuk pelatihan multilayer jaringan syaraf tiruan dengan algoritma pembelajaran yang terawasi dan biasanya digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot-bobot yang berhubungan dengan neuron-neuron yang ada pada lapisan tersembunyi [9, 10].

Pada algoritma jaringan syaraf tiruan backpropagation ini digunakan fungsi aktivasi sigmoid biner dimana fungsi ini bernilai antara 0 sampai dengan 1. Namun fungsi sigmoid biner tersebut tidak pernah mencapai angka 0 maupun 1. Fungsi aktivasi sigmoid biner dirumuskan pada persamaan (1) di bawah ini: [6-8]

$$f(x) = \frac{1}{1 + e^{-ax}} \quad \dots\dots\dots (1)$$

Oleh sebab itu data perlu di normalisasi terlebih dulu Dengan persamaan (2) dibawah ini :

$$x' = \frac{0.8(x - a)}{(b - a)} + 0.1 \quad \dots\dots\dots (2)$$

di mana a = Data minimum
 b = Data maksimum
 x = Data asal
 x' = Data ternormalisasi

Proses normalisasi data bertujuan agar nilai data input bisa disesuaikan dengan fungsi aktivasi sigmoid yang akan digunakan, agar jaringan tidak mengalami kegagalan ketika melakukan pembelajaran (pelatihan dan pengujian).

Pelatihan data dengan backpropagation terdiri dari

a. Menentukan arsitektur jaringan, dilakukan beberapa kali percobaan untuk mendapatkan jaringan terbaik dengan langkah-langkah sebagai berikut:

1. Kumpulkan data, normalisasi data, membagi data menjadi 2 yaitu data pelatihan dan pengujian, dan tentukan masing-masing target pada pelatihan dan pengujian.
2. Masukkan data pelatihan yang telah dinormalisasi `net=newff(minmax(data_latih),[5],{'logsig','purelin'},'traingdx')`; untuk membangun jaringan arsitektur JST. Tentukan hidden layer,output, fungsi aktivasi dan algoritma pelatihan.
3. Menetapkan bobot awal
`Bobot_hidden = net_keluaran.lw{1,1}`
`Bobot_keluaran = net_keluaran.LW {2,1};`
`Bias_hidden = net_keluaran.b{1,1};`
`Bias_keluaran = net_keluaran.b{2,1};`
4. Menetapkan parameter yang akan digunakan pada proses pelatihan sebagai berikut :
`>>net.trainParam.Lr=0,1;`
`>>.net.trainParam.goal=0,001`
`>>net.trainparam.show =100;`
`>>net.trainParam.epochs=2000;`
5. menjalankan simulasi program pelatihan
`[net_keluaran,tr,Y,E]=train(net,data_latih,target_latih);`

Pada jaringan feedforward (umpan maju), pelatihan dilakukan dalam rangka perhitungan bobot sehingga pada akhir pelatihan akan diperoleh bobot-bobot yang baik. Selama proses pelatihan, bobot-bobot diatur secara iteratif untuk meminimumkan error (kesalahan) yang terjadi. Kesalahan dihitung berdasarkan rata-rata kuadrat kesalahan (MSE). Rata-rata kuadrat kesalahan juga dijadikan dasar perhitungan untuk kerja fungsi aktivasi. MSE dihitung menggunakan persamaan (3):

$$MSE = \frac{\sum_{i=1}^n e_i^2}{n} \quad \dots\dots\dots (3)$$

Dengan :
 e_i^2 = selisih antara nilai target dengan nilai keluaran prediksi
 n = jumlah data pembelajaran

b. Setelah model peramalan diperoleh, berikutnya dilakukan langkah-langkah menentukan prediksi jumlah mahasiswa baru sebagai berikut :

1. Prediksi dilakukan menggunakan model jaringan terbaik

- Jalankan program dengan arsitektur jaringan terbaik.
- Setelah mendapatkan hasil simulasi kemudian di denormalisasi, yaitu mengembalikan kembali nilai hasil prediksi jaringan ke bentuk data semula (sebelum normalisasi) menggunakan rumus pada persamaan (4) sebagai berikut [3].

$$x = \frac{(x' - 0.1)(x_{\max} - x_{\min})}{0.8} + x_{\min} \dots\dots\dots (4)$$

Dengan : x' = data normalisasi

x_{\max} = data maksimum asli

x_{\min} = data minimum asli

Berikut ini hasil penelitian sesuai tahap-tahap yang sudah dijelaskan sebelumnya :

a. Pengumpulan data

- Mempersiapkan data mahasiswa baru Universitas Nasional dalam kurun waktu 3 tahun terakhir (tahun 2014-2017).

Tabel 1. Data Jumlah Mahasiswa Baru Universitas Nasional Tahun 2013/2014-2017/2018

TAHUN	2013/2014	2014/2015	2015/2016	2016/2017	2017/2018
FISIP	243	258	329	517	655
FE	213	237	324	399	547
SASTRA	150	161	165	142	260
FH	123	123	207	271	273
BIOLOGI	62	87	112	150	130
TEKSA	139	158	193	226	204
FTAN	25	28	34	24	54
ILKES	207	392	777	888	624
FIKI	188	191	227	344	388
AAN	15	15	0	0	0
ABANAS	46	71	76	92	44
AKPARNAS	36	56	23	37	20
MIP	24	46	60	59	50
MM	33	28	55	65	49
MH	37	33	71	56	47
MIA	49	27	56	52	43
S2 BIOLOGI	0	0	0	14	8
S3 POLTIK	10	12	9	10	6

Dari data pada tabel 1 di atas, yang akan digunakan sebagai data pelatihan adalah data tahun 2014/2015 sampai tahun 2016/2017, dan sebagai data pengujian adalah data tahun 2017/2018, yaitu data yang akan diprediksi. Untuk proses pelatihannya dilakukan per tahun, jadi data pelatihan tahun 2014/2015 akan diuji untuk data tahun 2015/2016, kemudian data pelatihan tahun 2015/2016 akan diuji untuk data tahun 2016/2017 dan terakhir data pelatihan tahun 2016/2017 akan diuji untuk data tahun 2017/2018, sebagai hasil prediksi dari sistem jaringan syaraf tiruan yang dibangun berdasarkan model arsitektur terbaik.

2. Normalisasi data

Setelah data di input, kemudian data pelatihan akan dinormalisasi terlebih dahulu dengan rumus seperti pada persamaan (4). Berikut ini adalah hasil normalisasi data pelatihan.

Tabel 2. Hasil Normalisasi Data Pelatihan

TAHUN	2014/2015	2015/2016	2016/2017	2017/2018
FISIP	0.3324	0.3963	0.5658	0.6901
FE	0.3135	0.3919	0.4594	0.5928
SASTRA	0.245	0.2486	0.2279	0.3342
FH	0.2108	0.2865	0.3441	0.3459
BIOLOGI	0.1784	0.2009	0.2351	0.2171
TEKSA	0.2423	0.2739	0.3036	0.2838
FTAN	0.1252	0.1306	0.1216	0.1486
ILKES	0.4532	0.8	0.9	0.6622
FIKI	0.2721	0.3045	0.4099	0.4495
AAN	0.1135	0.1	0.1	0.1
ABANAS	0.1639	0.1685	0.1829	0.1396
AKPARNAS	0.1505	0.1207	0.1333	0.118
MIP	0.1414	0.154	0.1532	0.145
MM	0.1252	0.1495	0.1585	0.1441
MH	0.1297	0.1639	0.1504	0.1423
MIA	0.1243	0.1504	0.1468	0.1387
S2 BIOLOGI	0.1	0.1	0.1126	0.1072
S3 POLTIK	0.1108	0.1081	0.109	0.1054

- Data yang sudah dinormalisasi akan dibagi menjadi dua bagian, yaitu sebagai data pelatihan dan data pengujian. Berikut contoh data pelatihan tahun 2014/2015 yang akan dilatih untuk mencapai data target tahun 2015/2016 dan sebagai data pengujian untuk hasil prediksi adalah data tahun 2016/2017.

Tabel 3. Data Pelatihan

PELATIHAN																			
No	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	X ₈	X ₉	X ₁₀	X ₁₁	X ₁₂	X ₁₃	X ₁₄	X ₁₅	X ₁₆	X ₁₇	Target	
1	0.3324	0.3324	0.245	0.2108	0.1784	0.2423	0.1252	0.4532	0.2721	0.1135	0.1639	0.1505	0.1414	0.1252	0.1297	0.1243	0.1	0.1081	0.3963
2	0.3324	0.245	0.2108	0.1784	0.2423	0.1252	0.4532	0.2721	0.1135	0.1639	0.1505	0.1414	0.1252	0.1297	0.1243	0.1	0.1081	0.3963	0.5658
3	0.3963	0.2108	0.1784	0.2423	0.1252	0.4532	0.2721	0.1135	0.1639	0.1505	0.1414	0.1252	0.1297	0.1243	0.1	0.1081	0.3963	0.5658	0.6901
4	0.2108	0.1784	0.2423	0.1252	0.4532	0.2721	0.1135	0.1639	0.1505	0.1414	0.1252	0.1297	0.1243	0.1	0.1081	0.3963	0.5658	0.6901	0.3324
5	0.1784	0.2423	0.1252	0.4532	0.2721	0.1135	0.1639	0.1505	0.1414	0.1252	0.1297	0.1243	0.1	0.1081	0.3963	0.5658	0.6901	0.3324	0.2108
6	0.2423	0.1252	0.4532	0.2721	0.1135	0.1639	0.1505	0.1414	0.1252	0.1297	0.1243	0.1	0.1081	0.3963	0.5658	0.6901	0.3324	0.2108	0.1784
7	0.1252	0.4532	0.2721	0.1135	0.1639	0.1505	0.1414	0.1252	0.1297	0.1243	0.1	0.1081	0.3963	0.5658	0.6901	0.3324	0.2108	0.1784	0.2423
8	0.4532	0.2721	0.1135	0.1639	0.1505	0.1414	0.1252	0.1297	0.1243	0.1	0.1081	0.3963	0.5658	0.6901	0.3324	0.2108	0.1784	0.2423	0.1252
9	0.2721	0.1135	0.1639	0.1505	0.1414	0.1252	0.1297	0.1243	0.1	0.1081	0.3963	0.5658	0.6901	0.3324	0.2108	0.1784	0.2423	0.1252	0.4532
10	0.1135	0.1639	0.1505	0.1414	0.1252	0.1297	0.1243	0.1	0.1081	0.3963	0.5658	0.6901	0.3324	0.2108	0.1784	0.2423	0.1252	0.4532	0.2721
11	0.1639	0.1505	0.1414	0.1252	0.1297	0.1243	0.1	0.1081	0.3963	0.5658	0.6901	0.3324	0.2108	0.1784	0.2423	0.1252	0.4532	0.2721	0.1135
12	0.1505	0.1414	0.1252	0.1297	0.1243	0.1	0.1081	0.3963	0.5658	0.6901	0.3324	0.2108	0.1784	0.2423	0.1252	0.4532	0.2721	0.1135	0.1639
13	0.1414	0.1252	0.1297	0.1243	0.1	0.1081	0.3963	0.5658	0.6901	0.3324	0.2108	0.1784	0.2423	0.1252	0.4532	0.2721	0.1135	0.1639	0.1505
14	0.1252	0.1297	0.1243	0.1	0.1081	0.3963	0.5658	0.6901	0.3324	0.2108	0.1784	0.2423	0.1252	0.4532	0.2721	0.1135	0.1639	0.1505	0.1414
15	0.1297	0.1243	0.1	0.1081	0.3963	0.5658	0.6901	0.3324	0.2108	0.1784	0.2423	0.1252	0.4532	0.2721	0.1135	0.1639	0.1505	0.1414	0.1252
16	0.1243	0.1	0.1081	0.3963	0.5658	0.6901	0.3324	0.2108	0.1784	0.2423	0.1252	0.4532	0.2721	0.1135	0.1639	0.1505	0.1414	0.1252	0.1297
17	0.1	0.1081	0.3963	0.5658	0.6901	0.3324	0.2108	0.1784	0.2423	0.1252	0.4532	0.2721	0.1135	0.1639	0.1505	0.1414	0.1252	0.1297	0.1243
18	0.1081	0.3963	0.5658	0.6901	0.3324	0.2108	0.1784	0.2423	0.1252	0.4532	0.2721	0.1135	0.1639	0.1505	0.1414	0.1252	0.1297	0.1243	0.1

Tabel 4. Data Pengujian

PENGUJIAN																			
No	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	X ₈	X ₉	X ₁₀	X ₁₁	X ₁₂	X ₁₃	X ₁₄	X ₁₅	X ₁₆	X ₁₇	X ₁₈	Target
1	0.3963	0.5658	0.2446	0.2067	0.2009	0.2739	0.1709	0.8	0.3045	0.1	0.1685	0.1207	0.154	0.1495	0.1639	0.1504	0.1	0.1081	0.5658
2	0.5658	0.2446	0.2067	0.2009	0.2739	0.1709	0.8	0.3045	0.1	0.1685	0.1207	0.154	0.1495	0.1639	0.1504	0.1	0.1081	0.5658	0.4594
3	0.2446	0.2067	0.2009	0.2739	0.1709	0.8	0.3045	0.1	0.1685	0.1207	0.154	0.1495	0.1639	0.1504	0.1	0.1081	0.5658	0.4594	0.2279
4	0.2067	0.2009	0.2739	0.1709	0.8	0.3045	0.1	0.1685	0.1207	0.154	0.1495	0.1639	0.1504	0.1	0.1081	0.5658	0.4594	0.2279	0.2446
5	0.2009	0.2739	0.1709	0.8	0.3045	0.1	0.1685	0.1207	0.154	0.1495	0.1639	0.1504	0.1	0.1081	0.5658	0.4594	0.2279	0.2446	0.2067
6	0.2739	0.1709	0.8	0.3045	0.1	0.1685	0.1207	0.154	0.1495	0.1639	0.1504	0.1	0.1081	0.5658	0.4594	0.2279	0.2446	0.2067	0.2009
7	0.1709	0.8	0.3045	0.1	0.1685	0.1207	0.154	0.1495	0.1639	0.1504	0.1	0.1081	0.5658	0.4594	0.2279	0.2446	0.2067	0.2009	0.2739
8	0.8	0.3045	0.1	0.1685	0.1207	0.154	0.1495	0.1639	0.1504	0.1	0.1081	0.5658	0.4594	0.2279	0.2446	0.2067	0.2009	0.2739	0.1709
9	0.3045	0.1	0.1685	0.1207	0.154	0.1495	0.1639	0.1504	0.1	0.1081	0.5658	0.4594	0.2279	0.2446	0.2067	0.2009	0.2739	0.1709	0.8
10	0.1	0.1685	0.1207	0.154	0.1495	0.1639	0.1504	0.1	0.1081	0.5658	0.4594	0.2279	0.2446	0.2067	0.2009	0.2739	0.1709	0.8	0.3045
11	0.1685	0.1207	0.154	0.1495	0.1639	0.1504	0.1	0.1081	0.5658	0.4594	0.2279	0.2446	0.2067	0.2009	0.2739	0.1709	0.8	0.3045	0.1
12	0.1207	0.154	0.1495	0.1639	0.1504	0.1	0.1081	0.5658	0.4594	0.2279	0.2446	0.2067	0.2009	0.2739	0.1709	0.8	0.3045	0.1	0.1685
13	0.154	0.1495	0.1639	0.1504	0.1	0.1081	0.5658	0.4594	0.2279	0.2446	0.2067	0.2009	0.2739	0.1709	0.8	0.3045	0.1	0.1685	0.1207
14	0.1495	0.1639	0.1504	0.1	0.1081	0.5658	0.4594	0.2279	0.2446	0.2067	0.2009	0.2739	0.1709	0.8	0.3045	0.1	0.1685	0.1207	0.154
15	0.1639	0.1504	0.1	0.1081	0.5658	0.4594	0.2279	0.2446	0.2067	0.2009	0.2739	0.1709	0.8	0.3045	0.1	0.1685	0.1207	0.154	0.1495
16	0.1504	0.1	0.1081	0.5658	0.4594	0.2279	0.2446	0.2067	0.2009	0.2739	0.1709	0.8	0.3045	0.1	0.1685	0.1207	0.154	0.1495	0.1639
17	0.1	0.1081	0.5658	0.4594	0.2279	0.2446	0.2067	0.2009	0.2739	0.1709	0.8	0.3045	0.1	0.1685	0.1207	0.154	0.1495	0.1639	0.1504
18	0.1081	0.5658	0.4594	0.2279	0.2446	0.2067	0.2009	0.2739	0.1709	0.8	0.3045	0.1	0.1685	0.1207	0.154	0.1495	0.1639	0.1504	0.1

4. Setelah menginput data pelatihan, selanjutnya melakukan pelatihan data dengan berbagai pola arsitektur seperti pada tabel 5

Tabel 5. Pelatihan data dengan berbagai pola arsitektur jaringan

No	Pola	Lr	Goal	Epoch	Fungsi Aktivasi	MSE
1	18-18-1	0,1	0,001	2000	Logsig - Purelin	0,009977289
2	18-17-1	0,1	0,001	2000	Logsig - Purelin	0,009517376
3	18-16-1	0,1	0,001	2000	Logsig - Purelin	0,009574789
4	18-15-1	0,1	0,001	2000	Logsig - Purelin	0,009985876
5	18-14-1	0,1	0,001	2000	Logsig - Purelin	0,009961769
6	18-13-1	0,1	0,001	2000	Logsig - Purelin	0,009988155
7	18-12-1	0,1	0,001	2000	Logsig - Purelin	0,009992393
8	18-11-1	0,1	0,001	2000	Logsig - Purelin	0,009968264
9	18-10-1	0,1	0,001	2000	Logsig - Purelin	0,009956817
10	18-9-1	0,1	0,001	2000	Logsig - Purelin	0,009965643
11	18-8-1	0,1	0,001	2000	Logsig - Purelin	0,009997883
12	18-7-1	0,1	0,001	2000	Logsig - Purelin	0,009901979
13	18-6-1	0,1	0,001	2000	Logsig - Purelin	0,009954992
14	18-5-1	0,1	0,001	2000	Logsig - Purelin	0,000998685
15	18-4-1	0,1	0,001	2000	Logsig - Purelin	0,002671194
16	18-3-1	0,1	0,001	2000	Logsig - Purelin	0,002863093
17	18-2-1	0,1	0,001	2000	Logsig - Purelin	0,00995133
18	18-1-1	0,1	0,001	2000	Logsig - Purelin	0,009981754

Pelatihan data dilakukan beberapa kali trial dan error untuk mendapatkan jaringan terbaik dengan menentukan jumlah neuron. Dengan jumlah *neuron* 5 dan *hidden layer* 1 didapatkan error terkecil (MSE) yaitu 0,000998685. Hasil pelatihan terbaik rancangan JST dilakukan kembali untuk pengujian dengan data uji yang telah disiapkan. Bobot terbaik disimpan untuk proses pengujian data agar didapatkan hasil uji yang baik juga.

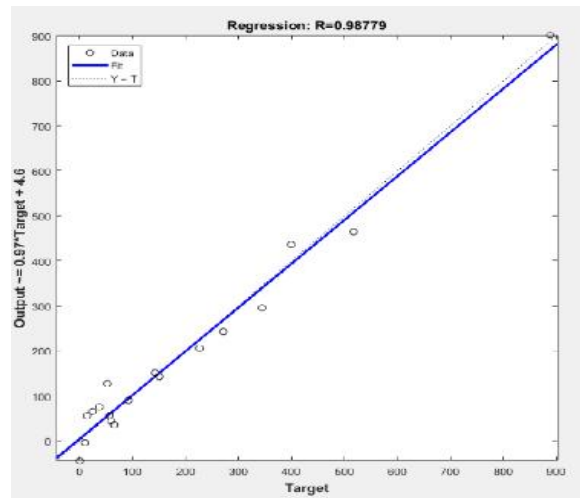
b. Pengujian data

Pengujian data dilakukan untuk mengukur validasi apakah hasil prediksi model yang dibangun dari data pelatihan memang memberikan hasil yang baik untuk menghitung error prediksi. Pengujian dilakukan menggunakan rancangan arsitektur terbaik yang telah diperoleh dari hasil pelatihan, Struktur jaringan yang digunakan terdiri dari satu lapis yang berisi 18 *neuron input*. Lapisan tersembunyi pertama terdiri dari 20 *neuron input* dan lapisan *output* terdiri dari 1 *neuron*. Data yang ada diubah menjadi pola pelatihan sebanyak 18 training dan 18 testing, sehingga diperoleh hasil data pengujian seperti pada tabel 6. Berdasarkan tabel 6 tersebut, model terbaik adalah dengan pola 18-5-1 didapatkan error terkecil (MSE) sebesar 0,000989309.

Tabel 6. Pengujian data dengan berbagai pola arsitektur jaringan

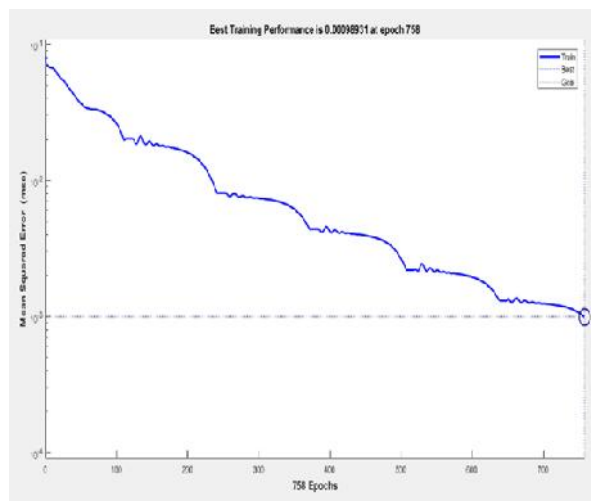
No	Pola	Lr	Goal	Epoch	Fungsi Aktivasi	MSE
1	18-18-1	0,1	0,001	2000	Logsig - Purelin	0,000998755
2	18-17-1	0,1	0,001	2000	Logsig - Purelin	0,000994141
3	18-16-1	0,1	0,001	2000	Logsig - Purelin	0,000999495
4	18-15-1	0,1	0,001	2000	Logsig - Purelin	0,000999533
5	18-14-1	0,1	0,001	2000	Logsig - Purelin	0,000999555
6	18-13-1	0,1	0,001	2000	Logsig - Purelin	0,000998395
7	18-12-1	0,1	0,001	2000	Logsig - Purelin	0,000994423
8	18-11-1	0,1	0,001	2000	Logsig - Purelin	0,000996826
9	18-10-1	0,1	0,001	2000	Logsig - Purelin	0,000994841
10	18-9-1	0,1	0,001	2000	Logsig - Purelin	0,00099624
11	18-8-1	0,1	0,001	2000	Logsig - Purelin	0,000999489
12	18-7-1	0,1	0,001	2000	Logsig - Purelin	0,000993876
13	18-6-1	0,1	0,001	2000	Logsig - Purelin	0,00099851
14	18-5-1	0,1	0,001	2000	Logsig - Purelin	0,000989309
15	18-4-1	0,1	0,001	2000	Logsig - Purelin	0,00099572
16	18-3-1	0,1	0,001	2000	Logsig - Purelin	0,001512306
17	18-2-1	0,1	0,001	2000	Logsig - Purelin	0,004008
18	18-1-1	0,1	0,001	2000	Logsig - Purelin	0,000998943

Untuk hasil pengujian data menggunakan model regresi untuk error/kesalahan, diperoleh hasil sebagai berikut :



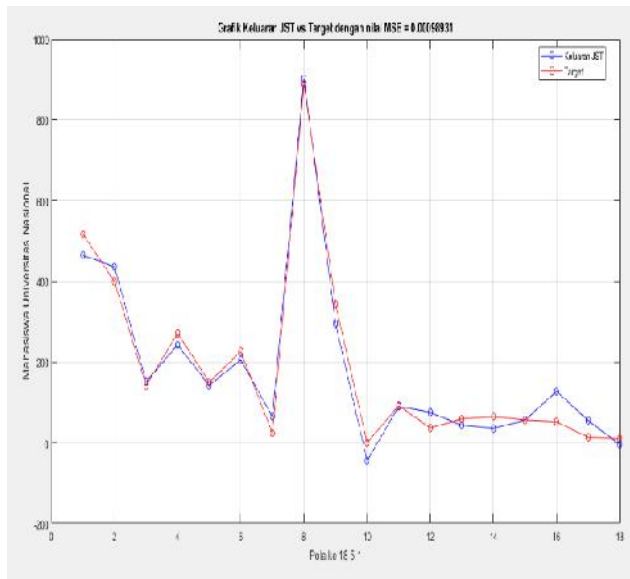
Gambar 3. Grafik pengujian data Tahun 2015/2016

Pada gambar 3. menunjukkan regresi dengan nilai R sebesar 0,98779 yang berarti antara variabel- variabel aktual dengan JST pada pengujian mempunyai korelasi yang baik. Setelah itu dilakukan perhitungan nilai MSE untuk pengujian tahun 2015/2016 dengan hasil sebagai berikut :



Gambar 4. Grafik Nilai MSE pada pengujian tahun 2015/2016

Pada gambar 4, hasil pengujian tercapai pada epoch 758 dan menghasilkan nilai MSE 0,000998685. Selanjutnya dilakukan perbandingan nilai keluaran dari model JST yang paling baik, yaitu yang mempunyai MSE paling kecil dan nilai target tahun 2016/2017 seperti terlihat pada gambar 5 berikut. Pada gambar 5 terlihat dari hasil perbandingan nilai keluaran JST dan nilai target tahun 2016/2017 diperoleh nilai MSE sebesar 0,000998685. Hasil ini menunjukkan bahwa prediksi untuk data tahun 2016/2017 akurat, karena MSE yang diperoleh kecil.



Gambar 5. Perbandingan Nilai Keluaran JST dan Nilai Target Tahun 2016/2017

c. Peramalan atau prediksi data

Setelah pelatihan dan pengujian data, selanjutnya dilakukan prediksi mahasiswa tahun 2017/2018. Prediksi ini menggunakan JST terbaik dengan rancangan arsitektur neuron 5-1 yang didapatkan pada trial and error di pelatihan data yaitu learning rate 0,1, fungsi aktivasi sigmoid biner untuk *hidden layer* dan purelin untuk *output layer*. Setelah disimulasikan maka didapatkan hasil JST yang merupakan nilai prediksi mahasiswa baru Universitas Nasional Tahun 2017/2018 di masing-masing fakultas seperti terlihat pada tabel 6 berikut ini :

Tabel 6. Prediksi mahasiswa baru tahun 2017/2018

TAHUN	Aktual	Prediksi	Error	%Error	%Akurasi	
F A K U L T A S	FISIP	655	507	148	22.59542	77.40458
	FE	547	357	190	34.734918	65.265082
	SASTRA	260	168	92	35.384615	64.615385
	FH	273	276	3	1.0989011	98.901099
	BIOLOGI	130	86	44	33.846154	66.153846
	TEKSA	204	260	56	27.45098	72.54902
	FTAN	54	32	22	40.740741	59.259259
	ILKES	624	903	279	44.711538	55.288462
	FIKI	388	306	82	21.134021	78.865979
	AAN	0	22	22	-	-
	ABANAS	44	89	45	102.27273	2.2727273
	AKPARNAS	20	44	24	120	20
	MIP	50	55	5	10	90
	MM	49	57	8	16.326531	83.673469
	MH	47	45	2	4.2553191	95.744681
	MIA	43	160	117	272.09302	172.09302
S2 BIOLOGI	8	1	7	87.5	12.5	
S3 POLIHK	6	8	2	33.333333	66.666667	

Berdasarkan tabel 6 di atas, rata-rata prosentase akurasi hasil prediksi sebesar 69,5%. Hasil ini menunjukkan bahwa model JST yang dibangun cukup akurat untuk memprediksi jumlah mahasiswa Universitas Nasional tahun 2017/2018.

3. Kesimpulan

Jaringan Syaraf tiruan dengan Algoritma Backpropagation mampu memprediksi jumlah mahasiswa baru sesuai dengan pola yang dilatih berdasarkan nilai input yang menjadi kriteria.

Proses jaringan syaraf tiruan menggunakan data dari jumlah mahasiswa baru Universitas Nasional dalam kurun 3 tahun, dimana datanya akan dibagi menjadi pelatihan dan pengujian. Hasil dari penelitian menunjukkan bahwa backpropagation memiliki tingkat akurasi yang baik dalam prediksi mahasiswa baru dengan struktur neuron 5-1 dengan 1 (satu) hidden layer, learning rate (lr) yang digunakan 0,1 batas toleransi nilai MSE 0,001. Proses pengujian ini dihentikan pada epoch ke 758, Di mana akurasi dilihat dari hasil pengujian mempunyai nilai MSE 0,000998685. Karena fungsi kinerja tujuannya sudah tercapai (MSE = 0,000998685 < 0,001) menunjukkan hubungan antara target dengan ouput jaringan pada saat pengujian. Dari pengujian pada data pengujian antara output jaringan diperoleh target koefisien korelasi (R) bernilai 0,98779 dimana untuk hasil terbaik adalah bernilai 1. Hasil perbandingan nilai keluaran JST dan nilai target tahun 2016/2017 diperoleh nilai MSE sebesar 0,000998685. Untuk prediksi tahun 2017/2018, ternyata model JST yang digunakan memperoleh prosentase akurasi yang cukup baik yaitu rata-rata 69,5%.

Daftar Pustaka

- [1.] Hara Simbolon, Matias Julyus Fika Sirait, "Implementasi Jaringan Syaraf Tiruan Dalam Memprediki Jumlah Mahasiswa Baru dengan Menggunakan Metode Backpropagation (Studi kasus : STMIK Budidarma Medan)", STMIK Budidarma, 2015.
- [2.] Sandy Kosasi, "Penerapan Metode Jaringan Saraf Tiruan Backpropagation untuk Memprediksi Nilai Ujian Sekolah", STMIK Pontianak, *Jurnal Teknologi*, vol. 7, no. 1, pp 20-28, Juni 2014.
- [3.] Joni Eka Candra, "Prediksi Jumlah Penumpang Pesawat Udara Menggunakan Jaringan Syaraf Tiruan Metode Backpropagation Di Bandar Udara Hang Nadim Batam", Teknik Informatika, Universitas Putra Batam, 2015.
- [4.] Dahriani Hakim Tanjung, "Jaringan Saraf Tiruan dengan Backpropagation untuk Memprediksi Penyakit Asma", STMIK Potensi Utama Medan, *Creative Information Technology Journal*, *ojs.amikom.ac.id*, vol. 2, no. 1, 2014.
- [5.] Arif jumarwanto, Rudy Hartanto, Dhidik Prastyanto, "Aplikasi Jaringan Saraf Tiruan Backpropagation untuk Memprediksi Penyakit THT di Rumah Sakit Mardi Rahayu Kudus", *Jurnal Teknik Elektro*, vol. 1, no. 1, Universitas Negeri Semarang, 2009 .
- [6.] Ihram Aryudha Perdana, "Simulasi dan Prediksi Jumlah Penjualan Air Menggunakan Jaringan Syaraf Tiruan Backpropagation (Study Kasus : PDAM TIRTA KEPRI)", Universitas Maritim Raja Ali Haji, 2016.
- [7.] Sofika Enggari, "Prediksi Kebutuhan Logistik untuk Sistem Akademik dengan Menggunakan Jaringan Syaraf Tiruan Studi Kasus Universitas Putra Indonesia", Universitas Putera Indonesia, *Jurnal Teknologi*, vol. 3, no. 2, 2013.
- [8.] Stamos T. Karamouzis, Andreas Vretos, "An Artificial Neural Network for Predicting Student Graduation Outcomes", *Proceedings of the World Congress on Engineering and Computer Science*, 2008.
- [9.] Tsung- Lin Lee, " Backpropagation Neural Network for The Prediction of The Short-Term Storm Surge in Taichung Harbor,

Taiwan, *Engineering Applications of Artificial Intelligence*, vol. 21, issues 1, pp. 63-72, 2008.

- [10]K.Manikya Kanti, P. Srinivasa Rao, “ Prediction of Bead Geometry in Pulsed GMA Welding Using Backpropagation Neural Network”, *Journal of Materials Processing Technology*, vol. 200, issues 1-3, pp. 300-305, 2008.

Biodata Penulis

Lina Nurhani, memperoleh gelar Sarjana Komputer (S.Kom), Program Studi Teknik Informatika, Universitas Nasional.

Aris Gunaryati, memperoleh gelar Sarjana Matematika (S.Si), Universitas Indonesia Jakarta, lulus tahun 2001. Memperoleh gelar Magister Manajemen Sistem Informasi (MMSI), Program Pasca Sarjana Magister Manajemen Sistem Informasi Universitas Gunadarma Jakarta, lulus tahun 2013. Saat ini menjadi Dosen di Universitas Nasional Jakarta.

Septi Andryana, memperoleh gelar Sarjana Komputer (S.Kom), Jurusan Manajemen Informatika Universitas Gunadarma Jakarta, lulus tahun 1995. Memperoleh gelar Magister Manajemen Sistem Informasi (MMSI), Program Pasca Sarjana Magister Manajemen Sistem Informasi Universitas Gunadarma Jakarta, lulus tahun 2008. Saat ini menjadi dosen di Universitas Nasional Jakarta.

Iskandar Fitri, memperoleh gelar Sarjana Teknik (Ir.), Jurusan Teknik Elektro, Universitas Nasional Jakarta, lulus Tahun 2000. Memperoleh gelar Magister Teknik (M.T), Program Pasca Sarjana Magister Teknik Elektro, Universitas Indonesia Jakarta, lulus tahun 2003. Memperoleh gelar Doktor (Dr.), Program Doktor Teknik Elektro Universitas Indonesia, lulus tahun 2008. Memperoleh Guru Besar (Profesor) di Universitas Nasional pada tahun 2016. Saat ini menjadi dosen di Universitas Nasional Jakarta.