

PENDAFTARAN MAHASISWA BARU PROGRAM PENDIDIKAN DASAR MENGUNAKAN ALGORITMA NN BACKPROPAGATION DI UPBJJ-UNIVERSITAS TERBUKA PROVINSI SULAWESI TENGAH

Syahrullah¹⁾, Hajra Rasmita Ngemba²⁾, Syaiful Hendra³⁾

^{1), 2)} Sistem Informasi STMIK ADHI GUNA Palu

³⁾ Teknik Informatika STMIK ADHI GUNA Palu
Jl Undata No. 3, Palu, Sulawesi Tengah

Email : syahrullah@gmail.com¹⁾, hajra.rasmita@gmail.com²⁾, syaiful.hendra.garuda@gmail.com³⁾

Abstrak

Penelitian ini membahas bagaimana cara melakukan prediksi pendaftaran mahasiswa baru program pendidikan dasar menggunakan algoritma Neural Network (NN) backpropagation. Penelitian ini bertujuan untuk membuat model prediksi dan untuk mengetahui kemampuan algoritma NN backpropagation dalam memprediksi pendaftaran mahasiswa baru. Dari hasil penelitian yang dilakukan algoritma NN backpropagation mampu memodelkan prediksi pendaftaran mahasiswa baru dan memiliki tingkat kesalahan prediksi (*forecasting error*) yang baik dalam memprediksi pendaftaran mahasiswa baru dengan nilai Mean Square Error (MSE) pada pengujian dataset *pendas* = 19.256.

Kata kunci: Pendaftaran Mahasiswa, Algoritma, Neural Network, Backpropagation.

1. Pendahuluan

Salah satu program Universitas Terbuka yaitu Program Pendidikan Dasar (Pendas) yang diperuntukkan bagi guru-guru pendidikan dasar (Guru SD) dan Guru Pendidikan Anak Usia Dini (PAUD). Pada pelaksanaan belajar-mengajar di UPBJJ-UT Provinsi Sulawesi Tengah sering terjadi kekurangan sumber daya maupun infrastruktur. Namun yang perlu mendapatkan perhatian lebih adalah ketersediaan jumlah tenaga pengajar/dosen karena ketidak mampuan panitia atau penyelenggara UPBJJ-UT dalam mengantisipasi jumlah mahasiswa baru. Untuk itu akan lebih baik jika penyelenggara mampu melakukan antisipasi untuk meminimalisir kelemahan yang ada dengan membuat model peramalan dalam melakukan prediksi jumlah mahasiswa baru yang akan masuk.

Peramalan (*forecasting*) adalah perkiraan sesuatu yang akan terjadi di masa mendatang yang pada umumnya dilakukan atas dasar data yang digunakan pada masa lampau dengan melakukan analisa terhadap data-data tersebut menggunakan metode ilmiah atau ilmu teknologi tertentu yang bertujuan untuk meminimalisir

kesalahan/ketidakpastian (*forecasting error*) yang dilakukan secara sistematis [1]. Untuk meramalkan kejadian yang akan datang didasari dengan data dan pengalaman kejadian yang sebelumnya serta algoritma yang tepat untuk menghitungnya. Terdapat beberapa algoritma untuk membuat model dan meramalkan kejadian yang akan datang, salah satu algoritma tersebut adalah Neural Network (NN). Algoritma NN mampu memodelkan permasalahan yang kompleks dengan memetakan nilai masa lampau dan nilai masa depan dari data *time series* dengan proses belajar seperti yang dilakukan oleh manusia [2].

Penelitian prediksi pendaftaran mahasiswa baru sudah pernah dilakukan oleh Shyi-Ming, C. & Chia-Cing, H., mengajukan metode baru dalam memprediksi hal yang sama pendaftaran mahasiswa baru pada Universitas Alabama menggunakan metode *fuzzy time series* [3], pada penelitian ini melakukan pembagian interval terhadap data yang akan digunakan menjadi lebih tepat guna meningkatkan hasil peramalan. Penelitian yang sama juga pernah dilakukan oleh Setyoutami, A. dkk. untuk memprediksi kunjungan pasien poli bedah pada Rumah Sakit Onkologi dengan metode yang digunakan adalah *fuzzy time series* [4].

Berdasarkan fenomena tersebut rumusan penelitian adalah bagaimana cara melakukan prediksi jumlah pendaftaran mahasiswa baru program pendidikan dasar pada UPBJJ-UT Sulawesi Tengah. Dengan tujuan membuat model prediksi jumlah pendaftaran mahasiswa baru program pendidikan dasar dan mengetahui kemampuan algoritma NN dengan model *backpropagation* dalam memprediksi jumlah pendaftaran mahasiswa baru. Model analisis *backpropagation* mudah diimplementasikan dan memiliki kelebihan dalam proses pembelajaran diawasi selama pelatihan dan memperbaiki bobot dalam proses pembelajaran balik hingga dikategorikan setepat mungkin oleh jaringan [5]. Penggunaan algoritma tersebut memberikan hasil yang baik dalam peramalan seperti yang dilakukan oleh [2].

Landasan Teori

Data Mining

Tan mengemukakan definisi *data mining* "merupakan kumpulan basis data yang diproses untuk mendapatkan atau menggali informasi yang lebih bermanfaat untuk tujuan tertentu guna membantu dalam pengambilan keputusan" [6]. Larose, D.T., mendefinisikan istilah data mining adalah analisis dan pengamatan data dengan skala besar untuk menemukan informasi yang tidak terduga serta merangkum data tersebut dengan cara yang lebih canggih guna mendapatkan informasi yang lebih bagi pemilik data [7]. Pemanfaatan data mining dapat dikelompokkan dalam empat model yaitu: model prediksi, analisis kelompok (*cluster analysis*), analisis asosiasi (*association analysis*), dan deteksi anomali.

Algoritma Neural Network (NN)

Artificial Neural Network (ANN) atau yang dikenal dengan jaringan saraf tiruan merupakan paradigma pengolahan informasi yang terinspirasi oleh sistem saraf secara biologis, seperti proses informasi pada otak manusia. Elemen kunci dari paradigma ini adalah struktur dari pengolahan informasi yang terjadi dari sejumlah besar elemen pemrosesan yang saling berhubungan (neuron), bekerja secara bersama-sama untuk menyelesaikan masalah tertentu [8].

Metode Backpropagation

Backpropagation adalah metode penurunan gradien untuk meminimalkan kuadrat error dari hasil keluaran [8]. Algoritma *Backpropagation* merupakan salah satu model jaringan yang sering digunakan pada jaringan NN. *Backpropagation* memiliki tiga tahap pelatihan [8], yaitu: perambatan maju, tahap perambatan balik, dan tahap perubahan bobot dan bias. Model jaringan ini banyak digunakan untuk penyelesaian suatu masalah yang berkaitan dengan identifikasi, prediksi, pengenalan pola dan sebagainya. Metode pelatihan *Backpropagation* merupakan *supervised training* dimana setiap pola *input* terdapat pasangan target *output* untuk masing-masing pola *input*.

Algoritma *Backpropagation* biasanya diterapkan pada *Perceptron* yang memiliki banyak lapisan (*Multi Layer Perceptrons*). *Perceptron* paling tidak mempunyai bagian *input*, *output* dan lapisan yang berada diantara *input* dan *output*. Lapis yang berada diantara *input* dan *output* disebut lapisan tersembunyi (*hidden layers*), bisa satu, dua dan seterusnya.

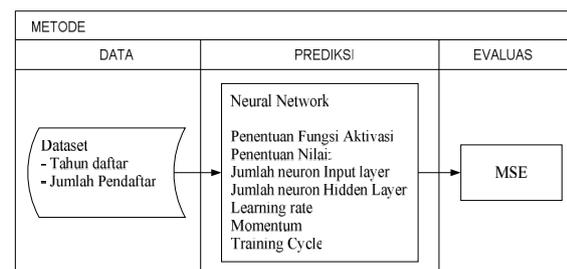
Moving Average (MA)

Moving Average (rata-rata bergerak) merupakan model peramalan yang berbasis pemulusan (*smoothing*), yakni melakukan rata-rata terhadap data yang fluktuasi untuk

menghilangkan pengaruh data iregular yang bersifat random [1]. Model MA juga banyak digunakan dalam melakukan peramalan, model peramalan pada MA sama dengan model peramalan yang lain yaitu menggunakan data historis (masa lalu) untuk dipelajari dalam proses peramalan. Pada pengujian dataset dalam penelitian ini, hasil dari model pengujian dengan MA akan dibandingkan dengan model yang diajukan yaitu NN *Backpropagation*.

Metode Penelitian

Jenis penelitian yang dilakukan adalah dengan metode eksperimen, yaitu untuk membuat model prediksi dan mengukur kemampuan algoritma NN untuk memprediksi jumlah pendaftaran mahasiswa baru. Data yang akan diolah diperoleh dari *database* pendaftaran mahasiswa baru Unit Program Belajar Jarak Jauh Universitas Terbuka (UPBJJ-UT), yang merupakan kumpulan dari data-data pendaftaran dimulai tahun 1990 semester satu sampai dengan 2013 semester dua. Metode yang diusulkan adalah penggunaan pendekatan teknik *data mining* dengan menggunakan algoritma NN dengan model *Backpropagation* untuk tahap pelatihan dan tahap pengujian dataset.



Gambar 1: Metode yang diusulkan

Untuk memilih arsitektur NN yang tepat, agar menghasilkan nilai *Mean Squared Error (MSE)* yang terkecil, diperlukan pengaturan (*adjustment*) untuk parameter-parameter NN. Berikut langkah-langkah proses tahapan pelatihan dalam mencari model yang paling baik untuk mendapatkan nilai MSE yaitu, penentuan fungsi aktivasi, penentuan jumlah *neuron* pada *input layer*, penentuan jumlah *neuron* pada *hidden layer*, penentuan nilai *learing rate*, penentuan nilai *momentum*, penentuan nilai *training cycle*, dan *output layer*. Untuk melihat tingkat keberhasilan dan kemampuan algoritma dalam membuat model prediksi pendaftaran mahasiswa baru pada arsitektur jaringan yang digunakan dalam penelitian ini, dengan menggunakan pengukuran tingkat kesalahan prediksi *Mean Squared Error (MSE)*.

2. Pembahasan

Dataset Pendas

Secara grafis data Pendas (Pendidikan Dasar) dapat dilihat pada gambar 3 data yang akan digunakan untuk pelatihan dan pengujian dalam membuat model prediksi pendaftaran mahasiswa baru program pendidikan dasar dimulai tahun 1990 semester 1 sampai dengan penerimaan mahasiswa baru 2013 semester 2. Dataset ini dipilih karena pendaftaran mahasiswa baru pendidikan dasar merupakan salah satu yang terbesar pada UPBJJ UT Provinsi Sulawesi Tengah, berikut grafiknya:



Gambar 2. Grafik pendaftaran mahasiswa baru program pendidikan dasar.

Pengujian Dataset Program Pendidikan Dasar (pendas)

Membuat model prediksi pendaftaran mahasiswa baru guna menghasilkan pola arsitektur jaringan NN terbaik sehingga diperoleh tingkat kesalahan peramalan (*forecasting error*) terkecil yang diukur menggunakan MSE. Maka pada penelitian ini melakukan pengujian dataset yang diawali dengan penentuan jumlah *neuron* pada *input layer* yang bertujuan untuk mencari jumlah *neuron* pada *input layer* yang ideal, penentuan jumlah *neuron* pada *input layer* dilakukan percobaan dengan memasukkan data *range* antara 1 sampai 18. Sedangkan jumlah *neuron* pada *hidden layer* dipilih secara acak yang diawali dengan jumlah *neuron* 6, untuk nilai *learning rate*, *momentum*, *training cycle* yang digunakan dipilih secara acak. Untuk nilai *learning rate* = 0.5, nilai *momentum* = 0.5 dan *training cycle* yang digunakan adalah 10000 iterasi. Tabel 1 berikut merupakan hasil percobaan penentuan jumlah *neuron* pada *input layer*.

Tabel 1. Percobaan penentuan jumlah *neuron* pada *input layer*.

| Neuron | | | R | M | Error | MSE |
|--------|---|---|-----|-----|---------|------------|
| I | H | O | | | | |
| 1 | 6 | 1 | 0.5 | 0.5 | 1.68095 | 346191.722 |
| 2 | 6 | 1 | 0.5 | 0.5 | 0.2795 | 63162.478 |
| 3 | 6 | 1 | 0.5 | 0.5 | 0.1763 | 36640.887 |
| 4 | 6 | 1 | 0.5 | 0.5 | 0.08744 | 20986.212 |
| 5 | 6 | 1 | 0.5 | 0.5 | 0.07613 | 18135.489 |
| 6 | 6 | 1 | 0.5 | 0.5 | 0.08412 | 18991.437 |
| 7 | 6 | 1 | 0.5 | 0.5 | 0.0829 | 20202.554 |

| | | | | | | |
|----|---|---|-----|-----|---------|-----------|
| 8 | 6 | 1 | 0.5 | 0.5 | 0.07359 | 16368.331 |
| 9 | 6 | 1 | 0.5 | 0.5 | 0.05256 | 10234.044 |
| 10 | 6 | 1 | 0.5 | 0.5 | 0.04141 | 10398.861 |
| 11 | 6 | 1 | 0.5 | 0.5 | 0.02976 | 8113.444 |
| 12 | 6 | 1 | 0.5 | 0.5 | 0.00866 | 3046.325 |
| 13 | 6 | 1 | 0.5 | 0.5 | 0.00801 | 2009.231 |
| 14 | 6 | 1 | 0.5 | 0.5 | 0.0041 | 1012.379 |
| 15 | 6 | 1 | 0.5 | 0.5 | 0.00107 | 396.943 |
| 16 | 6 | 1 | 0.5 | 0.5 | 0.00929 | 2236.627 |
| 17 | 6 | 1 | 0.5 | 0.5 | 0.00738 | 3971.686 |
| 18 | 6 | 1 | 0.5 | 0.5 | 0.00445 | 3196.491 |

Ket: I: Input; H: Hidden; O:Output; R: Rate; M: Momentum.

Berdasarkan hasil pengujian penentuan nilai jumlah *neuron* pada *input layer* yang telah dilakukan pada tabel 1, maka diperoleh nilai MSE terkecil 396.943 pada jumlah *neuron* pada *input layer* 15. Nilai *neuron* pada *Input layer* dengan MSE terkecil digunakan untuk menentukan nilai jumlah *neuron* pada *hidden layer*. Untuk menentukan jumlah *neuron* pada *hidden layer* yang ideal dilakukan dengan cara memasukkan nilai *input layer* dengan *range* nilai 1 sampai 18 untuk melihat pengaruh terhadap pergerakan nilai MSE. Untuk nilai jumlah *neuron* pada *Input layer* yang digunakan adalah nilai yang diperoleh sebelumnya yaitu 15, sedangkan untuk nilai *training cycle*, *momentum*, dan *learning rate* yang digunakan adalah masing-masing 10000 untuk nilai *training cycle*, nilai *learning rate* = 0.5, dan nilai *momentum* = 0.5. Tabel 2 berikut adalah hasil percobaan dari penentuan nilai *neuron* pada *hidden layer*.

Tabel 2. Percobaan penentuan jumlah *neuron* pada *hidden layer*

| Neuron | | | R | M | Error | MSE |
|--------|----|---|-----|-----|---------|------------|
| I | H | O | | | | |
| 15 | 1 | 1 | 0.5 | 0.5 | 0.4949 | 136017.12 |
| 15 | 2 | 1 | 0.5 | 0.5 | 0.52023 | 136379.131 |
| 15 | 3 | 1 | 0.5 | 0.5 | 0.53775 | 134676.554 |
| 15 | 4 | 1 | 0.5 | 0.5 | 0.01365 | 9375.825 |
| 15 | 5 | 1 | 0.5 | 0.5 | 0.00524 | 1568.198 |
| 15 | 6 | 1 | 0.5 | 0.5 | 0.00107 | 396.943 |
| 15 | 7 | 1 | 0.5 | 0.5 | 0.00086 | 290.783 |
| 15 | 8 | 1 | 0.5 | 0.5 | 0.00035 | 87.158 |
| 15 | 9 | 1 | 0.5 | 0.5 | 0.00104 | 355.723 |
| 15 | 10 | 1 | 0.5 | 0.5 | 0.00089 | 190.101 |
| 15 | 11 | 1 | 0.5 | 0.5 | 0.00014 | 41.274 |
| 15 | 12 | 1 | 0.5 | 0.5 | 0.00098 | 253.566 |
| 15 | 13 | 1 | 0.5 | 0.5 | 0.00109 | 287.895 |

| | | | | | | |
|----|----|---|-----|-----|---------|---------|
| 15 | 14 | 1 | 0.5 | 0.5 | 0.00018 | 58.786 |
| 15 | 15 | 1 | 0.5 | 0.5 | 0.00082 | 202.372 |
| 15 | 16 | 1 | 0.5 | 0.5 | 0.00009 | 23.444 |
| 15 | 17 | 1 | 0.5 | 0.5 | 0.00014 | 34.536 |
| 15 | 18 | 1 | 0.5 | 0.5 | 0.00056 | 138.372 |

Ket: I: Input; H: Hidden; O:Output; R: Rate; M:Momentum.

Berdasarkan hasil pengujian penentuan nilai jumlah *neuron* pada *hidden layer* yang telah dilakukan pada tabel 2, maka diperoleh nilai MSE terkecil 23.444 pada jumlah *neuron* pada *hidden layer* 16. Sehingga model arsitektur jaringan NN *backpropagation* yang dipilih adalah **15-16-1**, atau jumlah *neuron* pada *input layer* = 15, jumlah *neuron* pada *hidden layer* = 16 dan *output* =1. Untuk mengurangi tingkat kesalahan peramalan diperlukan nilai laju pembelajaran (*learning rate*) dan *momentum* guna mengoptimalkan kinerja algoritma NN *backpropagation*. Percobaan selanjutnya adalah menentukan nilai *learning rate* yang tepat, nilai *learning rate* yang akan digunakan adalah mulai dari 0.1 sampai 1. Sedangkan untuk nilai *momentum* yang digunakan dipilih secara acak, yaitu 0.5, dari percobaan tersebut dengan menggunakan pola arsitektur jaringan NN *backpropagation* adalah **15-16-1**. Tabel 3 merupakan hasil percobaan penentuan nilai *learning rate*.

Tabel 3. Hasil Percobaan Penentuan nilai *learning rate*.

| Neuron | | | R | M | Error | MSE |
|--------|----|---|-----|-----|---------|----------|
| I | H | O | | | | |
| 15 | 16 | 1 | 0.1 | 0.5 | 0.02603 | 8237.855 |
| 15 | 16 | 1 | 0.2 | 0.5 | 0.00341 | 906.425 |
| 15 | 16 | 1 | 0.3 | 0.5 | 0.00308 | 803.95 |
| 15 | 16 | 1 | 0.4 | 0.5 | 0.00035 | 91.278 |
| 15 | 16 | 1 | 0.5 | 0.5 | 0.00009 | 23.444 |
| 15 | 16 | 1 | 0.6 | 0.5 | 0.00007 | 19.256 |
| 15 | 16 | 1 | 0.7 | 0.5 | 0.00029 | 435.931 |
| 15 | 16 | 1 | 0.8 | 0.5 | 0.00028 | 422.243 |
| 15 | 16 | 1 | 0.9 | 0.5 | 0.00027 | 128.714 |
| 15 | 16 | 1 | 1 | 0.5 | 0.00005 | 52.226 |

Ket: I: Input; H: Hidden; O:Output; R: Rate; M:Momentum.

Berdasarkan hasil pengujian dataset pada tabel 3 menunjukkan bahwa nilai MSE terkecil diperoleh pada *learning rate* 0.6 dengan nilai MSE=19.256, Nilai *learning rate* dipilih berdasarkan nilai MSE terkecil. Nilai MSE tersebut digunakan sebagai dasar untuk menentukan nilai *momentum*. Nilai *momentum* juga mempengaruhi kinerja dari algoritma NN *backpropagation*, karena nilai *momentum* adalah waktu yang digunakan algoritma selama proses pembelajaran. Nilai *momentum* yang digunakan adalah *range* antara 0.1 sampai dengan 1. Sedangkan untuk jumlah *neuron* pada *Input layer*, jumlah *neuron* pada *Hidden Layer*, *Output*

adalah nilai pola arsitektur jaringan NN *backpropagation* yang telah diperoleh sebelumnya yaitu masing-masing **15-16-1** dan nilai *learning rate* yang digunakan adalah berdasarkan nilai yang yang diperoleh sebelumnya yaitu **0.6**. Tabel 4 merupakan hasil percobaan penentuan nilai *momentum*.

Tabel 4. Hasil percobaan penentuan nilai *momentum*

| Neuron | | | R | M | Error | MSE |
|--------|----|---|-----|-----|---------|------------|
| I | H | O | | | | |
| 15 | 16 | 1 | 0.6 | 0.1 | 0.00043 | 371.159 |
| 15 | 16 | 1 | 0.6 | 0.2 | 0.00128 | 323.692 |
| 15 | 16 | 1 | 0.6 | 0.3 | 0.00075 | 928.662 |
| 15 | 16 | 1 | 0.6 | 0.4 | 0.00072 | 156.496 |
| 15 | 16 | 1 | 0.6 | 0.5 | 0.00007 | 19.256 |
| 15 | 16 | 1 | 0.6 | 0.6 | 0.00327 | 913.381 |
| 15 | 16 | 1 | 0.6 | 0.7 | 0.00097 | 560.455 |
| 15 | 16 | 1 | 0.6 | 0.8 | 0.00126 | 242.742 |
| 15 | 16 | 1 | 0.6 | 0.9 | 0.00284 | 794.872 |
| 15 | 16 | 1 | 0.6 | 1 | 4.44188 | 1341397.17 |

Ket: I: Input; H: Hidden; O:Output; R: Rate; M:Momentum.

Berdasarkan hasil percobaan pada tabel 4 tersebut menunjukkan bahwa nilai MSE terkecil = 19.256 diperoleh pada *momentum* 0.5 Nilai *momentum* yang dipilih adalah berdasarkan nilai MSE terkecil yang diperoleh. Untuk memastikan pembuktian hasil percobaan tersebut dilakukan pengujian selama 5 kali dengan nilai pola arsitektur jaringan jumlah *neuron* pada *input layer*-jumlah *neuron* pada *hidden layer*-*otput* serta nilai *momentum* =0.5 dan *learning rate* 0.6, sehingga diperoleh 5 hasil pengujian seperti pada tabel 5 berikut:

Tabel 5. Lima hasil terbaik percobaan

| Neuron | | | R | M | Error | MSE | Perco baan |
|--------|----|---|-----|-----|---------|--------|---------------|
| I | H | O | | | | | |
| 15 | 16 | 1 | 0.6 | 0.5 | 0.00007 | 19.256 | 1 |
| 15 | 16 | 1 | 0.6 | 0.5 | 0.0017 | 21.269 | 2 |
| 15 | 16 | 1 | 0.6 | 0.5 | 0.0023 | 31.591 | 3 |
| 15 | 16 | 1 | 0.6 | 0.5 | 0.0072 | 203.96 | 4 |
| 15 | 16 | 1 | 0.6 | 0.5 | 0.0044 | 45.883 | 5 |

Ket: I: Input; H: Hidden; O:Output; R: Rate; M:Momentum.

Hasil percobaan tersebut menunjukkan bahwa tidak adanya penurunan nilai MSE dari 5 kali percobaan dengan pola arsitektur jaringan yang digunakan. Untuk itu, dari hasil pengujian dataset pendas diperoleh pola arsitektur jaringan NN *backpropagation* sebagai yaitu, *Jumlah neuron pada input layer* 15, *Jumlah neuron pada Hidden Layer* 16, *Learning Rate* 0.6, *Momentum* 0.5, dan *Jumlah Iterasi (Epoch)* 10000.

Perbandingan Model Fungsi Aktivasi pada dataset pendas

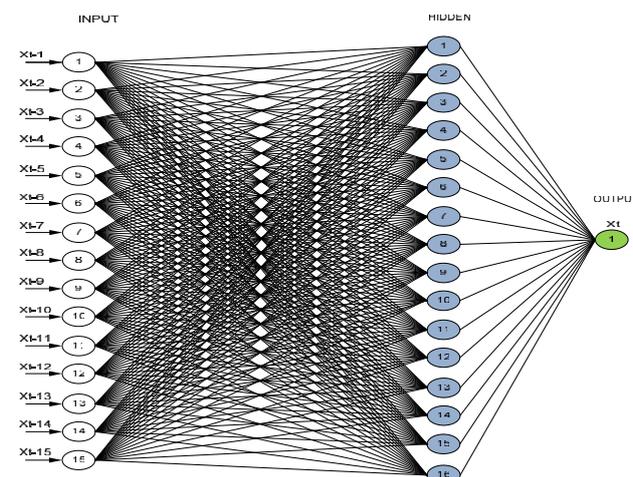
Selanjutnya adalah membandingkan empat fungsi aktivasi, guna untuk memastikan bahwa fungsi aktivasi yang digunakan memiliki tingkat kesalahan prediksi MSE terkecil. Fungsi aktivasi tersebut diantaranya adalah: (1) *Bipolar Sigmoid*, *Semi Linear*, *Sigmoid*, *Hyperbolic Tangent*. Untuk membandingkan fungsi aktivasi tersebut dengan menggunakan pola arsitektur jaringan NN *backpropagation* yang telah diperoleh sebelumnya, yaitu **15-16-1** serta nilai *momentum* = 0.5, *learning rate* = 0.6, *training cycle* = 10000 yang sama. Tabel 6 merupakan hasil percobaan dari empat fungsi aktivasi.

Tabel 6. Percobaan perbandingan 4 fungsi aktivasi.

| Activation Function | Neuron | | | R | M | Error | MSE |
|---------------------|--------|----|---|-----|-----|----------|-------------|
| | I | H | O | | | | |
| Semi Linear | 15 | 16 | 1 | 0.6 | 0.5 | 0.35182 | 554494.7107 |
| Sigmoid | 15 | 16 | 1 | 0.6 | 0.5 | 0.01018 | 14453.377 |
| Bipolar Sigmoid | 15 | 16 | 1 | 0.6 | 0.5 | 0.00007 | 19.256 |
| Hyperbolic Tangent | 15 | 16 | 1 | 0.6 | 0.5 | 46.09896 | 13921371.42 |

Ket: I: Input; H: Hidden; O:Output; R: Rate; M: Momentum

Berdasarkan hasil pengujian terhadap keempat fungsi aktivasi tersebut pada Tabel 6 menunjukkan bahwa tingkat kesalahan prediksi yang paling rendah dan ditunjukkan pada nilai MSE terkecil pada fungsi aktivasi *bipolar sigmoid*, dengan demikian pola arsitektur jaringan NN *backpropagation* **15-16-1**, pola tersebut dapat dilihat pada gambar 4 berikut:



Gambar 3. Arsitektur NN *backpropagation* dengan pola 15-16-1 dari hasil pengujian dataset pendas.

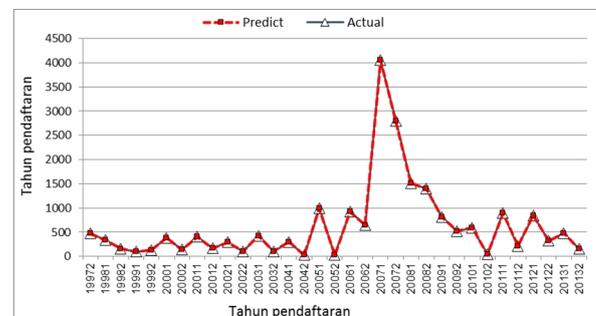
Gambar 4 menunjukkan bahwa terdapat 15 neuron pada input layer ($x_{t-1}, x_{t-2}, x_{t-3}, \dots, x_{t-15}$) yang menerima input berupa data tahun dan jumlah pendaftaran, nilai $x_{t-1}, x_{t-2}, x_{t-3}, \dots, x_{t-15}$ akan diberikan kepada unit hidden layer yang berjumlah 16 (1,2,3,...,16) untuk

diproses, hasil proses tersebut menghasilkan output (x_t) berupa prediksi jumlah pendaftaran mahasiswa program pendidikan dasar pada tahun yang akan diprediksi.

Prediksi Pendaftaran Mahasiswa Baru Program Pendidikan Dasar (Pendas)

Pola arsitektur jaringan NN *backpropagation* (jumlah neuron input layer jumlah neuron hidden layer-output layer) **15-16-1** yang merupakan pola arsitektur jaringan terbaik yang dipilih untuk memprediksi pendaftaran mahasiswa baru program pendidikan dasar, Tabel 4.10 merupakan hasil pengujian dari pola arsitektur jaringan NN *backpropagation* yang dilakukan, sehingga diperoleh perbandingan antara data actual dan prediksi pendaftaran mahasiswa baru program pendidikan dasar (pendas).

Berdasarkan hasil pengolahan data ditemukan bahwa untuk memprediksi jumlah pendaftaran mahasiswa baru program pendidikan dasar pada tahun (1997-2, 1998-1, 1998-2, ..., 2013-2) diperlukan input x_t ($x_{t-1}, x_{t-2}, x_{t-3}, \dots, x_{t-15}$) yang merupakan data jumlah pendaftaran dari tahun-tahun sebelumnya sebagai pembelajaran, dengan pola arsitektur jaringan NN *backpropagation* (**15-16-1**) maka diperoleh nilai prediksi (*bpnn predict*), sedangkan nilai *bpnn residual* merupakan selisih antara data hasil prediksi *bpnn predict* dan *data actual*. Secara grafis perbandingan antara hasil prediksi algoritma *bpnn* dan data actual dapat dilihat pada gambar 5 berikut:



Gambar 4. Perbandingan nilai actual dan prediksi pendaftaran mahasiswa baru program pendidikan dasar.

Berdasarkan gambar 5 bahwa antara data actual dan hasil prediksi sangat dekat dan tidak jauh berbeda, dengan demikian kemampuan algoritma NN *backpropagation* dalam memprediksi data *time series* menunjukkan hasil yang baik dengan tingkat *error* = 0.00007 dan MSE = 19.256.

Perkiraan jumlah pendaftaran mahasiswa baru program pendidikan dasar

Berdasarkan hasil pengujian dataset pendas yang telah dilakukan, untuk memprediksi pendaftaran mahasiswa baru pada 1 semester yang akan datang (*one step ahead*

prediction) yaitu Tahun Akademik 2014/1 diperlukan 15 data runtut waktu sebelumnya yaitu (2006/2, 2007/1, 2007/2, ..., 2013/2) atau jaringan NN *backpropagation* menerima input (X_{t-1} , X_{t-2} , X_{t-3} , ..., X_{t-15}) sebagai pebelajaran. hasil prediksi pendaftaran 1 semester pada tahun akademik 2014/1 yaitu 565 pendaftar.

Pengujian dengan Medel *Moving Average*(MA)

Pengujian ini menggunakan jumlah *moving*=15 (tahun 1990/1, 1990/2, 2001/1, ... 1997/1) sebagai pembelajaran, maka diperoleh nilai MSE = 755459.181 dan *Mean Absolute Percentage Error* (MAPE) = 225.711. Tabel 8 merupakan perbandingan hasil pengujian dengan metode MA dan NN *backpropagation* pada dataset pendas.

Tabel 7. Perbandingan prediksi MA dan NN *backpropagation* dataset pendas

| Tahun | Actual | BPNN Predict | BPNN Residual | MA Predict | MA Residual |
|------------|--------|---------------|---------------|-------------------|-------------|
| 1997-2 | 472 | 473.44 | -1.44 | 398.86 | 73.13 |
| 1998-1 | 334 | 329.37 | 4.63 | 421.33 | -87.33 |
| 1998-2 | 164 | 172.55 | -8.55 | 418.66 | -254.66 |
| ... | ... | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... |
| ... | ... | ... | ... | ... | ... |
| 2012-2 | 324 | 324.03 | -0.03 | 1086.07 | -762.06 |
| 2013-1 | 482 | 482.14 | -0.14 | 1041.60 | -559.6 |
| 2013-2 | 154 | 153.24 | 0.76 | 1071.67 | -917.66 |
| MSE | | 19.256 | | 755459.181 | |

Berdasarkan gambaran hasil perbandingan pengujian pada tabel 7 tersebut terhadap dataset pendas menunjukkan bahwa hasil prediksi menggunakan algoritma NN *backpropagation* memiliki nilai MSE terkecil yaitu 19.256 dibandingkan dengan model MA yang memperoleh nilai MSE = 755459.181, hal ini menunjukkan bahwa algoritma yang diajukan lebih baik dibandingkan dengan model MA.

3. Kesimpulan

Melakukan prediksi pendaftaran mahasiswa baru pada UPBJJ-UT Provinsi Sulawesi Tengah dapat dilakukan dengan membuat pola prediksi dengan Algoritma NN *backpropagation*, dimana hasil pengujian dataset yang telah dilakukan Algoritma NN *backpropagation* yang diajukan mampu menghasilkan arsitektur jaringan yang tepat dan tingkat kesalahan prediksi (*forecasting error*) dengan nilai *Mean Square Error* (MSE) terkecil dan nilai *error* terendah yang hampir mendekati 0 (nol). Hasil pengujian dataset pendas diperoleh pola arsitektur jaringan NN *backpropagation* 15-16-1, pada *learning rate* = 0.6, *momentum* = 0.5 dan diperoleh nilai MSE = 19.256, dan nilai *error* sebesar = 0.00007.

Daftar Pustaka

- [1] Santoso, S., *Business Forecasting Metode Peramalan Bisnis Masa Kini dengan MINITAB dan SPSS*. Jakarta, Indonesia: Elex Media Komputindo, 2009.
- [2] Wardani U.G.S., *Penggunaan Algoritma Genetik Dan Artificial Neural Network Untuk Peramalan Harga Saham*, Industrial Engineering and Management Institut Teknologi Bandung, Jakarta, Indonesia, Thesis 2008.
- [3] Shyi-Ming, C. & Chia-Cing, H., A New Method to Forecast Enrollments Using Fuzzy Time Series, *International Journal of Applied Science and Engineering*, vol. 2, no. 3, pp. 234-244, 2004.
- [4] Setyoutami, A. dkk., *Prediksi Jumlah Kunjungan Pasien Poli Bedah Di Rumah Sakit Onkologi Surabaya Menggunakan Fuzzy Time Series*, in *SESINDO 2012-Jurusan Sistem Informasi ITS*, Surabaya, November 2012, pp. 66-76.
- [5] Turban, E., dkk., *Decision Suport Systems and Intelligent Systems, 2nd ed. Terjemahan: P., Siska*. Jogjakarta, Indonesia: Penerbit Andi, 2005.
- [6] Prasetyo, E., *Data Mining Konsep dan Aplikasi menggunakan MATLAB.*, Jogjakarta, Indonesia: Penerbit Andi, 2011.
- [7] Larose, D.T., *Data Mining Methods And Models, 2nd ed.* Hoboken, New Jersey, United States of America: A JOHN WILEY & SONS, INC PUBLICATION, 2006.
- [8] T. Sutejo, dkk., *Kecerdasan Buatan, Benedicta Rini, Ed.* Jogjakarta, Indonesia: Penerbit Andi, 2011.

Biodata Penulis

Syahrullah, memperoleh gelar Sarjana Komputer (S.Kom), Jurusan Sistem Informasi STMIK Adhi Guna Palu, lulus tahun 2009. Memperoleh gelar Magister Komputer (M.Kom) Program Pasca Sarjana Magister Teknik Informatika Universitas Dian Nusantoro Semarang, lulus tahun 2013. Saat ini menjadi Dosen di STMIK Adhi Guna Palu.

Hajra Rasmita Ngemba, memperoleh gelar Sarjana Komputer (S.Kom), Jurusan Sistem Informasi Pariwisata Universitas Kristen Satya Wacana Salatiga, lulus tahun 2011. Memperoleh gelar *Double Degree* Magister Komputer (M.Kom) Program Pasca Sarjana Magister Teknik Informatika Universitas Islam Indonesia Yogyakarta dan gelar Magister Manajemen (MM) pada Program Pasca Sarjana Magister Manajemen Universitas Muhammadiyah Yogyakarta, lulus di tahun yang sama 2015. Saat ini menjadi Dosen di STMIK Adhi Guna Palu.

Syaiful Hendra, memperoleh gelar Sarjana Komputer (S.Kom), Jurusan Teknik Informatika STMIK Adhi Guna Palu, lulus tahun 2011. Memperoleh gelar Magister Komputer (M.Kom) Program Pasca Sarjana Magister Teknik Informatika Universitas Islam Indonesia Yogyakarta, lulus tahun 2015. Saat ini menjadi Dosen di STMIK Adhi Guna Palu.