

Peramalan Jumlah Wisatawan Mancanegara di Provinsi Kalimantan Timur Menggunakan Fuzzy Backpropagation Neural Network

Rina Aprilianti¹, Ika Purnamasari², Surya Prangga³

¹Mahasiswa Statistika, Universitas Mulawarman

^{2,3}Dosen Statistika, Universitas Mulawarman

apriliantirina22@gmail.com¹, ika.purnamasari@fmipa.unmul.ac.id², suryaprangge@gmail.com³

Diajukan 30 April 2023 *Diperbaiki* 19 Juni 2023 *Diterima* 23 Juni 2023

Abstrak

Latar Belakang: Pariwisata merupakan salah satu bidang ekonomi yang menjadi sumber penerimaan devisa bagi negara. Banyaknya wisatawan merupakan salah satu faktor yang dapat berpengaruh terhadap perkembangan pariwisata. Sepanjang tahun 2021, jumlah wisatawan mancanegara di Provinsi Kalimantan Timur mengalami penurunan. Penurunan tersebut merupakan dampak dari mewabahnya COVID-19. Peneliti melakukan peramalan jumlah wisatawan mancanegara di Kalimantan Timur menggunakan *Fuzzy Backpropagation Neural Network* (FBPNN) guna mengantisipasi kenaikan maupun penurunan jumlah wisatawan di masa mendatang. FBPNN adalah metode peramalan *Neural Network* (NN) yang menggunakan algoritma pembelajaran *backpropagation* dimana nilai *input* dan *output*-nya berupa derajat keanggotaan himpunan *fuzzy*.

Tujuan: Meramalkan jumlah wisatawan mancanegara di Kalimantan Timur pada bulan Januari 2022 sampai dengan Mei 2022.

Metode: Metode yang digunakan adalah *Fuzzy Backpropagation Neural Network* (FBPNN).

Hasil: Berdasarkan hasil prediksi FBPNN dengan proporsi 80%:20% untuk data *training* diperoleh *Root Mean Square Error* (RMSE) sebesar 113,61 sedangkan untuk RMSE data *testing* diperoleh adalah sebesar 108,45.

Kesimpulan: Adapun kesimpulan penelitian yaitu metode *Fuzzy Backpropagation Neural Network* dapat digunakan untuk meramalkan jumlah wisatawan dengan nilai RMSE yang dihasilkan oleh data *testing* lebih kecil jika dibandingkan dengan nilai RMSE yang dihasilkan oleh data *training*.

Kata kunci: FBPNN, Non Linier, Prediksi, RMSE

Abstract

Background: Tourism is one of the economic fields that is a source of foreign exchange earnings for the country. The number of tourists is one of the factors that can influence the development of tourism. Throughout 2021, the number of foreign tourists in East Kalimantan Province has decreased. This decrease was the impact of the COVID-19 outbreak. Researchers forecast the number of foreign tourists in East Kalimantan using the *Fuzzy Backpropagation Neural Network* (FBPNN) to anticipate increases or decreases in the number of tourists in the future. FBPNN is a *Neural Network* (NN) forecasting method that uses a *backpropagation* learning algorithm where the input and output values are in the form of membership degrees of fuzzy sets.

Objective: Forecasting the number of foreign tourists in East Kalimantan from January 2022 to May 2022.

Method: The method used is the *Fuzzy Backpropagation Neural Network* (FBPNN).

Results: Based on the FBPNN prediction results with a proportion of 80%:20% for training data, a *Root Mean Square Error* (RMSE) is obtained of 113.61 while for RMSE testing data obtained is 108.45.

Conclusion: The conclusion of the study is that the *Fuzzy Backpropagation Neural Network* method can be used to predict the number of tourists with the RMSE value generated by the testing data being smaller when compared to the RMSE value generated by the training data.

Keywords: FBPNN, Non Linear, Predict, RMSE

PENDAHULUAN

Serangkaian data yang disusun berdasarkan urutan dan panjang waktu tertentu yang sama disebut dengan data runtun waktu (Hansun, 2012). Analisis runtun waktu merupakan metode yang digunakan untuk meramalkan kejadian dimasa datang didasarkan pada kejadian di masa lampau (Durrah et al., 2018).

Metode peramalan merupakan metode estimasi kondisi yang mungkin terjadi pada waktu mendatang menggunakan data masa lampau (Suprayogi, 2022). Peramalan terhadap data runtun waktu terbagi menjadi beberapa metode, salah satunya adalah *Neural Network*. Sistem pada *Neural Network* (NN) memiliki karakteristik yang mirip dengan jaringan syaraf biologis (Achmalia et al., 2020). Terdapat dua jenis pada NN yaitu *Feedforward Neural Network* (FFNN) dan *Recurrent Neural Network* (RNN). FFNN atau yang lebih dikenal dengan sebutan *Backpropagation Neural Network* (BPNN) merupakan NN yang pergerakannya maju dari *input layer*, menuju *hidden layer*, sampai ke *neuron layer*, tanpa adanya perulangan (Yang et al., 2013). Adapun RNN merupakan NN yang memiliki karakteristik adanya perulangan, yang mana data inputan pada proses perulangan ini menggunakan nilai *neuron* pada *hidden layer* (Rizal & Soraya, 2018).

BPNN merupakan algoritma *training* dipakai untuk memproses bobot dengan tujuan meminimumkan error dalam *output* NN (Rifa'i, 2021). BPNN seringkali digunakan sebagai metode peramalan pada data runtun waktu, dikarenakan kemampuannya untuk menganalisa pola data dengan baik. Meskipun demikian, tidak dapat dipungkiri bahwa NN juga mempunyai kelemahan, yaitu kurang optimal jika digunakan untuk mengambil suatu keputusan.

Adapun kekurangan pada NN dapat diatasi dengan melakukan kombinasi

metode *Fuzzy* menghasilkan *Fuzzy Neural Network* (Fuller, 1995). Penggabungan *fuzzy* dan NN pertama kali dilakukan oleh (Lin & Lee, 1991). *Fuzzy* NN merupakan model NN yang dipakai untuk *processing* data dalam bentuk *fuzzy* (Park & Han, 2000). Pengembangan *fuzzy* NN telah dilakukan oleh banyak peneliti, salah satunya yaitu pengembangan *Fuzzy* NN, dimana NN yang digunakan adalah BPNN dengan tujuan untuk meningkatkan akurasi peramalan. Pengembangan *Fuzzy Backpropagation Neural Network* (FBPNN) tersebut dilakukan karena kombinasi dari keduanya menghasilkan peramalan dengan tingkat akurasi yang baik (Chang et al., 2005). FBPNN adalah metode peramalan NN yang menggunakan algoritma pembelajaran *backpropagation* dimana nilai *input* dan *output*-nya berupa derajat keanggotaan himpunan *fuzzy*. FBPNN pada dasarnya adalah jaringan syaraf tiruan yang didasari oleh arsitektur jaringan yang memiliki banyak lapisan yang didesain untuk memproses data-data pada himpunan *fuzzy*. Jaringan pada FBPNN terdiri *input layer*, *hidden layer*, dan *output layer* (Wiliansa & Kusumawati, 2017).

FBPNN dapat digunakan diberbagai bidang, salah satunya di bidang pariwisata. Pariwisata merupakan salah satu bidang ekonomi yang menjadi sumber penerimaan devisa bagi negara. Banyaknya wisatawan merupakan salah satu faktor yang dapat berpengaruh terhadap perkembangan pariwisata. Berdasarkan data Badan Pusat Statistik tahun 2021, jumlah wisatawan mancanegara telah mengalami kenaikan dan penurunan selama 5 tahun terakhir. Oleh karena itu, untuk mengantisipasi penurunan dan kenaikan jumlah wisatawan mancanegara kedepannya perlu dilakukan peramalan.

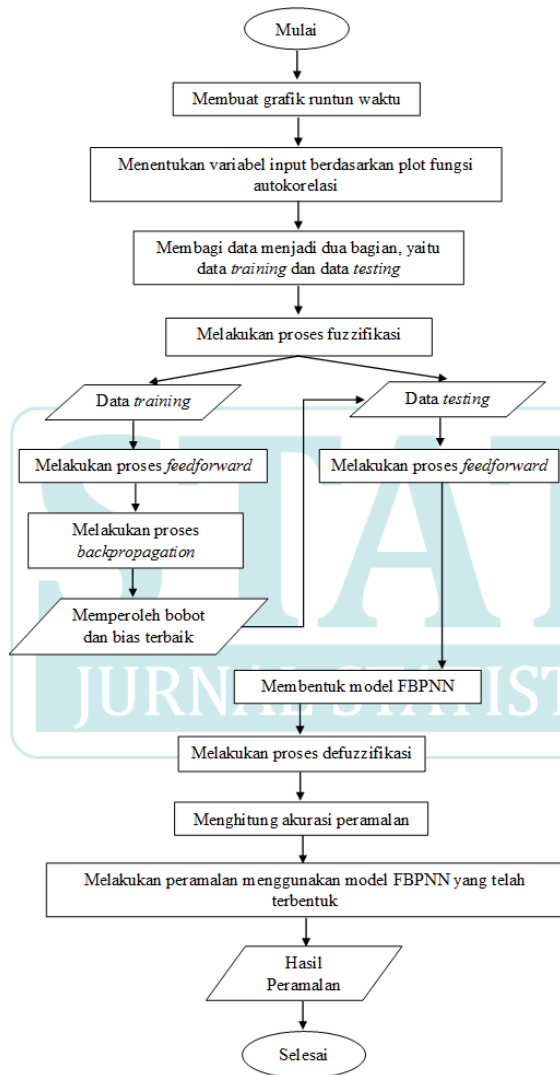
Penelitian menggunakan FBPNN sebelumnya pernah dilakukan oleh (Chen, 2003), pada penelitian tersebut diperoleh nilai RMSE metode FBNNN yaitu sebesar 171,82, sedangkan nilai RMSE dengan BPNN sebesar 173,27.

Tujuan penelitian ini yaitu mendapatkan model FBPNN untuk selanjutnya dapat diramalkan data Jumlah Wisatawan

Mancanegara Provinsi Kalimantan Timur untuk 5 periode ke depan, serta memperoleh tingkat akurasi peramalan data Jumlah Wisatawan Mancanegara Provinsi Kalimantan Timur.

METODE

Desain Penelitian



Populasi Dan Sampel

Adapun populasi pada penelitian ini ialah jumlah wisatawan mancanegara yang berkunjung ke Kalimantan Timur, sedangkan sampel yang digunakan adalah jumlah wisatawan mancanegara yang berkunjung ke Kalimantan Timur periode Januari 2017 sampai dengan Desember 2021.

Teknik Analisis Data

Adapun langkah-langkah yang dilakukan adalah sebagai berikut:

1. Melakukan analisis statistika deskriptif berupa grafik runtun waktu untuk mengetahui pola data jumlah wisatawan mancanegara Kalimantan Timur periode Januari 2017 sampai dengan Desember 2021.
2. Membuat plot fungsi autokorelasi ACF maupun PACF. Berdasarkan plot ACF dan PACF dilakukan pengujian sigifikansi untuk memastikan lag yang signifikan.
3. Berdasarkan uji signifikansi, plot ACF ataupun PACF yang memiliki jumlah lag signifikan paling banyak akan digunakan untuk menentukan variabel input.
4. Membagi data 80% training dan 20% testing.
5. Melakukan proses fuzzifikasi menggunakan fungsi keanggotaan kurva-S penyusutan dengan tahapan sebagai berikut:
 - a. Menentukan himpunan semesta pembicaraan U berdasarkan persamaan berikut:

$$U = [Y_{min} - D_1, Y_{max} - D_2] \quad (1)$$
 menggunakan data keseluruhan dengan panjang interval yang dihitung menggunakan persamaan berikut:

$$L = \frac{R}{4} \quad (2)$$
 - b. Dengan menggunakan fungsi keanggotaan kurva-S penyusutan, penentuan himpunan fuzzy memiliki 4 kelas. Sehingga semesta pembicaraan U yang terbentuk adalah $u_1, u_2, u_3,$ dan u_4 .
6. Melakukan pelatihan BPNN menggunakan fungsi aktivasi *sigmoid biner*, dengan tahapan sebagai berikut:
 - a. Menetapkan nilai iterasi maksimum, *target error*, dan *learning rate*. Nilai iterasi maksimum yang digunakan adalah sebanyak 50.000 iterasi, *target error* adalah sebesar 0,01, dan *learning rate* sebesar 0,5.
 - b. Inialisasi bobot awal dari bilangan random yang cukup kecil.

- c. Untuk setiap data *training*, melakukan langkah selanjutnya, yaitu langkah (d) sampai langkah (g)
- d. Melakukan proses *feedforward* dengan tahapan sebagai berikut:
- 1) Menghitung nilai *input* di *hidden layer* menggunakan nilai bobotnya berdasarkan persamaan berikut:

$$z_{in_j} = v_{0j} + \sum_{i=1}^p x_i v_{ij} \quad (3)$$
 kemudian menghitung sinyal *output* berdasarkan persamaan berikut:

$$z_j = f(z_{in_j}) \quad (4)$$
 - 2) Menghitung nilai *input* di *output layer* menggunakan nilai bobotnya berdasarkan persamaan berikut:

$$y_{in_m} = w_{0m} + \sum_{j=1}^q z_j w_{jm} \quad (5)$$
 kemudian menghitung sinyal *output* berdasarkan persamaan berikut:

$$y_m = f(y_{in_m}) \quad (6)$$
- e. Melakukan proses *backpropagation* dengan tahapan sebagai berikut:
- 1) Menghitung *error* pola target yang bersesuaian dengan pola input berdasarkan persamaan berikut:

$$\delta_m = (Y_m - y_m) f'(y_{in_m}) \quad (7)$$
 - 2) Menghitung koreksi nilai bobot dan koreksi bias yang akan digunakan untuk memperbaharui nilai bobot menggunakan persamaan (8) dan persamaan (9) berikut:

$$\Delta w_{jm} = \alpha \delta_m z_j \quad (8)$$

$$\Delta w_{0m} = \alpha \delta_m \quad (9)$$
 - 3) Menghitung delta *input* yang berasal dari unit pada *layer* di atasnya menggunakan persamaan berikut:

$$\delta_{in_j} = \sum_{m=1}^s \delta_m w_{jm} \quad (10)$$
 - 4) Menghitung faktor koreksi *error* menggunakan persamaan berikut:

$$\delta_j = (\delta_{in_j}) f'(z_{in_j}) \quad (11)$$
 - 5) Menghitung koreksi nilai bobot dan koreksi bias yang akan digunakan untuk memperbaharui nilai bobot menggunakan persamaan (12) dan persamaan (13) berikut:

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (12)$$

$$\Delta v_{0j} = \alpha \delta_j \quad (13)$$
 - f. Memperbarui nilai bobot dan bobot bias menggunakan persamaan (14) dan (15)

$$w_{jm}(\text{baru}) = w_{jm}(\text{lama}) + \Delta w_{jm} \quad (14)$$


$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (15)$$
 - g. Jika *target error* telah terpenuhi atau mencapai batas iterasi maksimum maka pelatihan *backpropagation* dihentikan. (Ujianto & Irawan, 2015)
7. Untuk data *testing*, dengan menggunakan nilai bobot dan bias terbaik dilakukan proses *feedforward* (langkah 6d) untuk memperoleh nilai prediksi.
 8. Membentuk model FBPNN berdasarkan proses fuzzifikasi dan BPNN yang telah dilakukan.
 9. Melakukan proses defuzzifikasi menggunakan fungsi keanggotaan yang digunakan pada proses fuzzifikasi, yang selanjutnya akan digunakan sebagai nilai prediksi.
 10. Menghitung tingkat akurasi peramalan menggunakan persamaan berikut:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (16)$$
 11. Menghitung nilai peramalan untuk periode kedepan.

HASIL DAN PEMBAHASAN

Pada penelitian ini digunakan data jumlah wisatawan mancanegara di Kalimantan Timur periode Januari 2017 sampai dengan Desember 2021. Berdasarkan data yang ada, dibuat grafik *time series* untuk melihat pola data. *Time series plot* dapat dilihat pada Gambar 1 berikut:

Peramalan Jumlah Wisatawan Mancanegara di Provinsi Kalimantan....




Gambar 1. Time Series Plot Jumlah Wisatawan Kalimantan Timur Periode Januari 2017 hingga Desember 2021


Berdasarkan Gambar 1 dapat dilihat bahwa data wisatawan mancanegara di Kalimantan Timur periode Januari 2017 sampai dengan Desember 2021 memiliki pola *trend* turun. Terjadi fluktuasi pada setiap bulannya di bulan Januari 2017 sampai dengan bulan November 2017. Dimana pada bulan Juli 2017 mencapai titik tertinggi yaitu sebesar 456 kunjungan. Kemudian, mengalami penurunan yang signifikan pada bulan Desember 2017 hingga bulan Februari 2018. Lalu, kembali mengalami fluktuasi pada bulan Maret 2018 sampai dengan bulan September 2019. Setelah itu, mengalami penurunan yang signifikan pada bulan Oktober 2019 hingga Desember 2019. Kemudian, mengalami kenaikan pada bulan Januari 2020. Dan kembali mengalami penurunan pada bulan Februari 2020 sampai dengan Desember 2021 dengan titik terendah berada pada bulan Desember 2020, dan Juni 2021 hingga Desember 2021.

Penentuan *Input* Fuzzy Backpropagation Neural Network (FBPNN)

Penentuan *input* FBPNN dilakukan berdasarkan banyaknya *lag* yang signifikan pada plot ACF dan plot PACF. Plot ACF dapat dilihat pada Gambar 2 berikut:



(a)



(b)

Gambar 2. Plot ACF dan Plot PACF Jumlah Wisatawan Kalimantan Timur Periode Januari 2017 hingga Desember 2021

Berdasarkan Gambar 2(a), secara visual dapat diketahui bahwa *lag* yang keluar dari batas signifikan sebanyak 5 *lag* yaitu *lag* ke-1 hingga *lag* ke-5. Kemudian, berdasarkan Gambar 2(b) dapat dilihat bahwa *lag* yang keluar dari batas signifikan sebanyak 2 *lag* yaitu *lag* ke-1 dan *lag* ke-2. Jumlah *lag* signifikan pada plot PACF lebih sedikit dibandingkan pada plot ACF, sehingga yang akan digunakan untuk menentukan *input* adalah plot ACF dengan *input* yang diperoleh adalah sebanyak 5 *input*.

Data yang digunakan sebagai data *input* diperoleh berdasarkan *lag* tertinggi yaitu *lag* ke-5, sehingga *t* dimulai dari data ke-6 hingga data ke-60 yaitu sebanyak 55 data. Untuk selanjutnya, dilakukan pembagian data *training* dan *testing*, melalui *trial and error*. Adapun pembagian data yang terbaik adalah pembagian data dengan proporsi 80:20, atau sebanyak 44 data *training* dan 11 data *testing*, sebagaimana pada Tabel 1 berikut:

Tabel 1. Data Training dan Data Testing

Data Training				Data Testing			
x_1	...	x_5	y	xs_1	...	xs_5	ys
370	...	409	281	14	...	9	15
281	...	322	456	15	...	1	25
456	...	402	419	25	...	15	21
419	...	356	452	21	...	0	16
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
15	...	34	0	0	...	0	0
0	...	13	14	0	...	0	0

Proses Fuzzifikasi

Penentuan Himpunan Semesta Pembicaraan U

Himpunan semesta pembicaraan ditentukan berdasarkan keseluruhan data baik data *training* maupun *testing*, yang mana data minimum pada himpunan semesta diperoleh sebesar 0 dan maksimum sebesar 456. Pada penelitian ini dilakukan *trial and error* untuk penentuan nilai D_1 dan D_2 yaitu $D_1 = 0$ dan $D_2 = 4$; serta $D_1 = 0$ dan $D_2 = 44$ dengan banyaknya *neuron* pada *hidden layer* adalah 1 sampai dengan 10 *neuron*. Selanjutnya, pada subbab ini akan disampaikan pembahasan terkait FBPNN dengan nilai $D_1 = 0$ dan $D_2 = 4$. Sehingga himpunan semesta pembicaraan (U) yang terbentuk yaitu:

$$U = [Y_{min} - D_1, Y_{max} - D_2]$$

$$U = [0 - 0, 456 + 4]$$

$$U = [0, 460]$$

Berdasarkan perhitungan yang telah dilakukan maka diperoleh himpunan semesta pembicaraan berada pada interval $[0, 460]$, yang artinya himpunan semesta pembicaraan tersebut akan menjadi batas bawah (Y_{min}) yaitu sebesar 0 dan batas atas (Y_{max}) yaitu sebesar 460. Setelah diperoleh nilai himpunan semesta pembicaraan, maka selanjutnya menentukan sub interval kelas himpunan semesta pembicaraan melalui proses partisi semesta pembicaraan (U). Partisi dilakukan untuk membentuk himpunan semesta pembicaraan (U) menjadi beberapa sub himpunan u_1, u_2, \dots, u_4 .

Partisi Semesta Pembicaraan

Semesta pembicaraan (U) yang telah diperoleh pada langkah sebelumnya akan dipartisi menjadi beberapa interval kelas dengan panjang interval kelas yang sama. Partisi himpunan semesta u_i dimana $i = 1, 2, \dots, 4$ dapat dituliskan sebagai berikut:

$$u_1 = [0, 115]$$

$$u_2 = [115, 230]$$

$$u_3 = [230, 345]$$

$$u_4 = [345, 460]$$

Selanjutnya dilakukan pendefinisian fungsi keanggotaan kurva-s penyusutan. Pendefinisian fungsi keanggotaan kurva-s penyusutan dapat dituliskan sebagai berikut:

$$\mu_{u_1}(x) = \begin{cases} 1, & x \leq 0 \\ 1 - 2 \left(\frac{x - 0}{115 - 0} \right)^2, & 0 \leq x \leq 57,5 \\ 2 \left(\frac{115 - x}{115 - 0} \right)^2, & 57,5 \leq x \leq 115 \\ 0, & x \geq 115 \end{cases}$$

$$\mu_{u_2}(x) = \begin{cases} 1, & x \leq 115 \\ 1 - 2 \left(\frac{x - 115}{230 - 115} \right)^2, & 115 \leq x \leq 172,5 \\ 2 \left(\frac{230 - x}{230 - 115} \right)^2, & 172,5 \leq x \leq 230 \\ 0, & x \geq 230 \end{cases}$$

$$\mu_{u_3}(x) = \begin{cases} 1, & x \leq 230 \\ 1 - 2 \left(\frac{x - 230}{345 - 230} \right)^2, & 230 \leq x \leq 287,5 \\ 2 \left(\frac{345 - x}{345 - 230} \right)^2, & 287,5 \leq x \leq 345 \\ 0, & x \geq 345 \end{cases}$$

$$\mu_{u_4}(x) = \begin{cases} 1, & x \leq 345 \\ 1 - 2 \left(\frac{x - 345}{460 - 345} \right)^2, & 345 \leq x \leq 402,5 \\ 2 \left(\frac{460 - x}{460 - 345} \right)^2, & 402,5 \leq x \leq 460 \\ 0, & x \geq 460 \end{cases}$$

Derajat Keanggotaan Fuzzy

Selanjutnya dilakukan penentuan derajat keanggotaan *fuzzy* dengan cara mensubstitusikan setiap *input* ke persamaan fungsi keanggotaan yang telah terbentuk. Misalnya untuk data pertama dari variabel *input* x_1 yaitu 370 berada pada sub himpunan ke-4 dengan interval $[345, 460]$, maka diperoleh nilai derajat keanggotaan *fuzzy* adalah sebagai berikut:

$$\mu_{u_4}(x) = 1 - 2 \left(\frac{x - 345}{460 - 345} \right)^2$$

$$\mu_{u_4}(370) = 1 - 2 \left(\frac{370 - 345}{460 - 345} \right)^2 = 0,9055$$

berdasarkan perhitungan yang telah dilakukan, diperoleh derajat keanggotaan sebesar 0,9055. Dengan cara yang sama dilakukan perhitungan derajat keanggotaan fuzzy untuk setiap data pada variabel input x_1, x_2, \dots, x_5 dan y data training serta variabel input xs_1, xs_2, \dots, xs_5 dan ys data testing.

Tabel 2. Derajat Keanggotaan Fuzzy Data Training

x_1				...	x_5			
μ_{u_1}	μ_{u_2}	μ_{u_3}	μ_{u_4}	...	μ_{u_1}	μ_{u_2}	μ_{u_3}	μ_{u_4}
0	0	0	0,905	...	0	0	0	0,393
0	0	0,607	1	...	0	0	0,080	1
0	0	0	0,002	...	0	0	0	0,509
0	0	0	0,254	...	0	0	0	0,982
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
0,966	1	1	1	...	0,825	1	1	1
1	1	1	1	...	0,974	1	1	1

Tabel 3. Derajat Keanggotaan Fuzzy Data Testing

xs_1				...	xs_5			
μ_{u_1}	μ_{u_2}	μ_{u_3}	μ_{u_4}	...	μ_{u_1}	μ_{u_2}	μ_{u_3}	μ_{u_4}
0,970	1	1	1	...	0,988	1	1	1
0,966	1	1	1	...	0,999	1	1	1
0,905	1	1	1	...	0,966	1	1	1
0,933	1	1	1	...	1	1	1	1
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1	1	1	1	...	1	1	1	1
1	1	1	1	...	1	1	1	1

Proses Backpropagation

Pada proses pembelajaran *backpropagation*, terdapat proses fuzzyfikasi terlebih dahulu pada data input dan target. Pada *hidden layer* dan *output layer* digunakan fungsi aktivasi sigmoid biner. *Learning rate* yang digunakan pada penelitian ini adalah sebesar 0,5. Target error yang digunakan adalah sebesar 0,01 dan maksimum iterasi yang digunakan adalah sebesar 50.000. Kemudian, dilakukan *trial and error* untuk penentuan jumlah *neuron* pada *hidden layer* yang digunakan. Berdasarkan *trial and error* yang telah dilakukan untuk penentuan jumlah *neuron* pada *hidden layer*, diperoleh jumlah *hidden layer* dengan nilai RMSE terkecil adalah 7 *neuron*.

1. Inisialisasi bobot dan bobot bias

Inisialisasi bobot v_{ij} dan bobot bias v_{0j} serta bobot w_{jm} dan bobot bias w_{0m} secara random dengan bilangan yang cukup kecil menggunakan bantuan *software R*. Diperoleh nilai bobot dan *error* sebagai berikut:

$$v = \begin{bmatrix} v_{01} & \dots & v_{07} \\ \vdots & \ddots & \vdots \\ v_{201} & \dots & v_{207} \\ 1,1358 & \dots & -0,9685 \\ \vdots & \ddots & \vdots \\ -0,3005 & \dots & -0,0655 \end{bmatrix}$$

$$w = \begin{bmatrix} w_{01} & \dots & w_{04} \\ \vdots & \ddots & \vdots \\ w_{71} & \dots & w_{74} \\ 1,0502 & \dots & 0,1301 \\ \vdots & \ddots & \vdots \\ -0,8026 & \dots & -1,5902 \end{bmatrix}$$

2. Tahap *feedforward*

Setelah diperoleh bobot awal, selanjutnya dilakukan perhitungan nilai *input* dan *ouput* setiap *neuron* di *hidden layer* serta menghitung nilai *input* dan *output* setiap *neuron* di *output layer* menggunakan fungsi aktivasi sigmoid biner.

3. Tahap *backpropagation*

Menghitung *error* dari *output* dan menghitung koreksi bobot dan bobot bias yang akan digunakan untuk memperoleh bobot baru.

4. Tahap pembaharuan nilai dari bobot dan bobot bias

Menentukan bobot dan bobot bias baru pada setiap *neuron* di *output layer* dan *hidden layer*

5. Melakukan langkah 2 sampai dengan langkah 4 menggunakan bobot dan bobot bias baru. Jika *target error* telah terpenuhi atau batas iterasi maksimum telah tercapai maka proses pelatihan dihentikan.

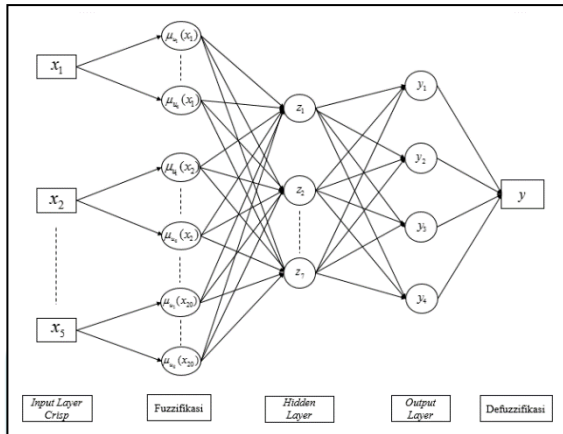
Nilai bobot dan bobot bias yang optimum untuk 7 *hidden layer* adalah sebagai berikut:

$$v = \begin{bmatrix} v_{01} & \dots & v_{07} \\ \vdots & \ddots & \vdots \\ v_{201} & \dots & v_{207} \\ -1,1756 & \dots & -4,0304 \\ \vdots & \ddots & \vdots \\ -0,2375 & \dots & 3,1384 \end{bmatrix}$$

$$w = \begin{bmatrix} w_{01} & \dots & w_{04} \\ \vdots & \ddots & \vdots \\ w_{71} & \dots & w_{74} \\ 1,5437 & \dots & 5,9644 \\ \vdots & \ddots & \vdots \\ -2,9091 & \dots & -3,9344 \end{bmatrix}$$

Setelah proses *backpropagation* dilakukan, maka dapat diperoleh model FBPNN dan arsitektur FBPNN yang terdiri dari 20 *neuron* pada *input layer*, 7 *neuron* pada *hidden layer*, dan 4 *neuron* pada *output layer* yang dapat dilihat pada persamaan (16) dan Gambar 3.

$$y_m = \frac{1}{1 + e^{-\left(w_{0m} + \sum_{j=1}^7 \frac{1}{1 + e^{-\left(v_{0j} + \sum_{i=1}^{20} x_i v_{ij}\right)} w_{jm}\right)}} \tag{17}$$



Gambar 3. Arsitektur FBPNN

Berdasarkan bobot optimum di atas diperoleh *output* jaringan untuk data *training* yang dapat dilihat pada Tabel 5.

Tabel 5. Output Jaringan Data Training

Data ke-	u_1	u_2	u_3	u_4
1	$7,6434 \times 10^{-6}$	$4,7589 \times 10^{-4}$	0,5964	0,9959
2	$1,9487 \times 10^{-8}$	$1,8311 \times 10^{-5}$	$5,1405 \times 10^{-5}$	0,0029
3	$1,3622 \times 10^{-9}$	$6,1113 \times 10^{-12}$	$2,2787 \times 10^{-10}$	0,2531
4	$2,8608 \times 10^{-8}$	$8,7178 \times 10^{-4}$	$5,7267 \times 10^{-7}$	0,0091
⋮	⋮	⋮	⋮	⋮
43	0,9849	1	0,9998	0,9999
44	0,9851	1	0,9998	0,9999

Setelah diperoleh *output* jaringan untuk data *training*, selanjutnya dilakukan proses *feedforward* untuk perhitungan prediksi data *testing* dengan menggunakan bobot dan bobot bias optimum yang diperoleh sebelumnya. *Output* jaringan untuk data *testing* dapat dilihat pada Tabel 6.

Tabel 6. Output Jaringan Data Testing

Data ke-	u_1	u_2	u_3	u_4
1	0,9851	0,9999	0,9999	0,9999
2	0,9849	0,9999	0,9999	0,9999
3	0,9845	0,9999	0,9999	0,9999
4	0,9844	0,9999	0,9999	0,9999
⋮	⋮	⋮	⋮	⋮
10	0,9852	0,9999	0,9999	0,9999
11	0,9852	0,9999	0,9999	0,9999

Defuzzifikasi

Setelah diperoleh *output* jaringan, selanjutnya *output* jaringan tersebut difuzzifikasi berdasarkan fungsi keanggotaan yang digunakan pada proses fuzzifikasi. Metode defuzzifikasi yang digunakan adalah metode *Smallest of Maximum Defuzzier* (SOM), dimana pada metode ini nilai *output* yang digunakan adalah dengan mengambil nilai terkecil dari domain yang memiliki nilai keanggotaan maksimum.

Misalnya, *output* hasil prediksi data *training* yang diperoleh untuk data ke-1 adalah $\hat{y} = [7,6434 \times 10^{-6} \ 4,7589 \times 10^{-4} \ 0,5964 \ 0,9959]$ kemudian dipilih nilai keanggotaan maksimum yaitu 0,9959 yang berada pada sub-himpunan *fuzzy* ke-4. Derajat keanggotaan tersebut kemudian disubsitusikan ke fungsi keanggotaan, diperoleh hasil perhitungan sebagai berikut:

$$\begin{aligned} \mu_{u_4}(x) &= 1 - 2 \left(\frac{x-345}{460-345} \right)^2 \\ 0,9959 &= 1 - 2 \left(\frac{x-345}{460-345} \right)^2 \\ x &= \frac{\sqrt{2-2(0,9959)} \times (460-345) + (2 \times 345)}{2} = 350,22 \\ \mu_{u_4}(x) &= 2 \left(\frac{460-x}{460-345} \right)^2 \\ 0,9959 &= 2 \left(\frac{460-x}{460-345} \right)^2 \\ x &= \frac{(2 \times 460) - \sqrt{2(0,9959)} \times (460-345)}{2} = 378,85 \end{aligned}$$

Berdasarkan perhitungan di atas, diperoleh dua nilai prediksi untuk derajat keanggotaan 0,9959 yaitu 350,22 dan 378,85. Dari dua nilai prediksi tersebut diambil nilai minimum yang digunakan sebagai nilai prediksi untuk data *training* ke-1 yaitu 350,22.

Kemudian dilakukan proses defuzzifikasi dengan cara yang sama untuk *output* jaringan dari data *training* ke-2 sampai data *training* ke-44. Diperoleh hasil prediksi untuk data *training* adalah sebagai berikut:

Peramalan Jumlah Wisatawan Mancanegara di Provinsi Kalimantan....

Tabel 7. Hasil Prediksi Data *Training*

Data ke-	Data Aktual	Prediksi
1	281	350,22
2	456	426,20
3	419	415,28
4	452	425,95
5	411	410,02
⋮	⋮	⋮
43	0	115,03
44	14	115,03

Setelah diperoleh hasil prediksi untuk data *training*, selanjutnya dilakukan proses defuzzifikasi untuk *output* jaringan data *testing*. Metode defuzzifikasi yang digunakan sama dengan metode defuzzifikasi untuk *output* jaringan data *training* yaitu metode *Smallest of Maximum Defuzzier* (SOM).

Kemudian dilakukan proses defuzzifikasi dengan cara yang sama untuk *output* jaringan dari data *testing*. Diperoleh hasil prediksi untuk data *testing* adalah sebagai berikut:

Tabel 8. Hasil Prediksi Data *Testing*

Data ke-	Data Aktual	Prediksi
1	15	115,0271
2	25	115,0272
3	21	115,0274
4	16	115,0275
5	0	115,0273
⋮	⋮	⋮
10	0	115,0270
11	0	115,0270

Tingkat Akurasi Prediksi

Setelah mendapatkan nilai prediksi dari proses defuzzifikasi, selanjutnya dilakukan perhitungan tingkat akurasi prediksi. Tingkat akurasi prediksi yang digunakan adalah *Root Mean Square Error* (RMSE). Perhitungan tingkat akurasi prediksi untuk data *training* adalah sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{t=1}^{44} (y_t - \hat{y}_t)^2}{44}}$$

$$RMSE = \sqrt{\frac{(281 - 350,22)^2 + \dots + (14 - 115,03)^2}{44}}$$

$$RMSE = 113,61$$

Selanjutnya dilakukan perhitungan tingkat akurasi prediksi untuk data *testing*, diperoleh nilai RMSE sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{t=1}^{11} (y_{st} - \hat{y}_{st})^2}{11}}$$

$$RMSE = \sqrt{\frac{(15 - 115,03)^2 + \dots + (0 - 115,03)^2}{11}}$$

$$RMSE = 108,45$$

Berdasarkan hasil prediksi data *training* dan data *testing* diperoleh nilai RMSE masing-masing sebesar 113,61 dan 108,45. Nilai RMSE pada data *testing* mengalami penurunan. Kemudian, disajikan nilai RMSE untuk $D_1 = 0$ dan $D_2 = 4$; serta $D_1 = 0$ dan $D_2 = 44$ dengan banyaknya *neuron* pada *hidden layer* adalah 1 sampai dengan 10 *neuron*.

Tabel 9. Nilai RMSE

Neuron	$D_1 = 0$ dan $D_2 = 4$		$D_1 = 0$ dan $D_2 = 44$	
	Training	Testing	Training	Testing
1	137,06	223,21	166,02	243,19
2	123,73	108,44	149,39	122,46
3	150,57	223,28	148,56	122,17
4	188,70	338,26	171,35	243,20
5	148,27	223,24	207,77	368,18
6	137,77	223,21	198,20	369,83
7	113,61	108,45	205,50	368,88
8	181,44	338,14	157,19	243,35
9	158,78	223,21	193,36	368,20
10	182,80	223,25	175,74	243,48


Peramalan FBPNN

Setelah dilakukan perhitungan RMSE hasil prediksi untuk data *training* dan *testing*. Selanjutnya dilakukan peramalan FBPNN untuk 5 periode ke depan yaitu bulan Januari 2022 sampai dengan bulan Mei 2022. Adapun hasil peramalan dapat dilihat pada Tabel 10 berikut.

Tabel 10. Hasil Peramalan

Periode ke-	Hasil Peramalan (Kunjungan)
61	115
62	115
63	230
64	230
65	232

Berdasarkan hasil peramalan pada Tabel 10. di atas dapat digambarkan grafik runtun waktu hasil peramalan Jumlah Wisatawan Mancanegara Kalimantan Timur periode Januari 2022 sampai dengan Mei 2022. Grafik perbandingan antara data aktual dan hasil peramalan menggunakan FBPNN dengan 7 neuron pada *hidden layer* dapat dilihat pada Gambar 4 berikut.



Gambar 4. Grafik Perbandingan Data Aktual dan Hasil Peramalan FBPNN dengan 7 Neuron Hidden Layer

Berdasarkan Gambar 4 dapat diketahui bahwa data hasil peramalan tidak mengikuti pola data aktual. Berdasarkan penelitian yang telah dilakukan hal tersebut dikarenakan *range* data minimum dan maksimum yang terlalu besar.

PENUTUP

Berdasarkan hasil penelitian, dapat disimpulkan bahwa hasil peramalan secara keseluruhan mengalami tren naik terutama pada bulan Maret 2022.

Penulis memberikan saran untuk penelitian selanjutnya dapat dilakukan peramalan FBPNN dengan menggunakan data yang memiliki pola data stasioner yang memiliki *range* data tidak terlalu besar agar hasil peramalan yang diperoleh

lebih baik.

DAFTAR PUSTAKA

- Achmalia, A. F., Walid, & Sugiman. (2020). Peramalan Penjualan Semen Menggunakan Backpropagation Neural Network dan Recurrent Neural Network. *UNNES Journal of Mathematics*, 9(1), 6–21. <https://doi.org/10.15294/ujm.v9i1.29970>
- Chang, P. C., Wang, Y. W., & Liu, C. H. (2005). Fuzzy back-propagation network for PCB sales forecasting. *Lecture Notes in Computer Science*, 3610, 364–373. https://doi.org/10.1007/11539087_45
- Chen, T. (2003). A Fuzzy Back Propagation Network For Output Time Prediction In a Wafer Fab. *Applied Soft Computing Journal*, 2(3), 211–222. [https://doi.org/10.1016/S1568-4946\(02\)00066-2](https://doi.org/10.1016/S1568-4946(02)00066-2)
- Durrah, F. I., Yulia, Parhusip, T. P., & Rusyana, A. (2018). Peramalan Jumlah Penumpang Pesawat Di Bandara Sultan Iskandar Muda Dengan Metode SARIMA (Seasonal Autoregressive Integrated Moving Average). *Journal of Data Analysis*, 1(1), 1–11. <https://doi.org/10.24815/jda.v1i1.11847>
- Fuller, R. (1995). *Neural Fuzzy Systems*. Abo Akademi.
- Lin, C. T., & Lee, C. S. G. (1991). Neural-Network-Based Fuzzy Inference Systems. *IEEE Trans On Computer*, 40(12), 1320–1336. <https://doi.ieeecomputersociety.org/10.1109/12.106218>
- Park, S., & Han, T. (2000). Iterative Inversion of Fuzzified Neural Networks. *IEEE Transactions on Fuzzy Systems*, 8(3), 266–280. <https://doi.org/10.1109/91.855916>
- Rifa'i, A. (2021). Prediksi Inflasi Indonesia

Berdasarkan Fuzzy ANN
Menggunakan Algoritma Genetika.
*Jurnal ELTIKOM : Jurnal Teknik
Elektro, Teknologi Informasi dan
Komputer*, 5(1), 12-24.
<https://doi.org/10.31961/eltikom.v5i1.215>

Rizal, A. A., & Soraya, S. (2018). Multi Time Steps Prediction dengan Recurrent Neural Network Long Short Term Memory. *Jurnal MATRIK: Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, 18(1), 115-124.
<https://doi.org/10.30812/matrik.v18i1.344>

Suprayogi, M. A. (2022). Model Double Exponential Smoothing Dalam Peramalan Penerimaan Pajak Pemerintah Pusat Indonesia. *Jurnal Statistika Dan Komputasi*, 1(2), 83-92.
<https://doi.org/10.32665/statkom.v1i2.1233>

Wiliansa, G., & Kusumawati, R. (2017). Optimasi Fuzzy Backpropagation Neural network Dengan Algoritma Genetika Untuk Memprediksi Nilai tukar rupiah Terhadap Dollar Amerika. *Jurnal Matematika*, 6(3), 10-20.

Yang, Y., Hu, J., Lv, Y., & Zhang, M. (2013). Predictions on the Development Dimensions of Provincial Tourism Discipline Based on the Artificial Neural Network BP Model. *Higher Education Studies*, 3(3).
<https://doi.org/10.5539/hes.v3n3p13>