

Metode *Radial Basis Function Neural Network* (RBFNN) untuk Peramalan Kunjungan Wisatawan dengan Perbandingan Kombinasi Fungsi Pelatihan

Istiqomah Ambarwati^{a,*}

^{a, b} Universitas Negeri Semarang, Gunungpati, Semarang, 50229, Indonesia

* Alamat Surel: istiqomahambar@students.unnes.ac.id

Abstrak

Kunjungan wisatawan mancanegara ke Indonesia memiliki peran penting bagi pertumbuhan ekonomi dari segi sektor pariwisata. Data kunjungan wisatawan merupakan data runtun waktu yang dapat digunakan untuk memprediksi dimasa mendatang. Jaringan syaraf tiruan merupakan salah satu metode yang dapat digunakan untuk memprediksi data nonlinier. *Radial Basis Function Neural Network* (RBF) adalah model jaringan syaraf yang mentransformasikan *input* secara nonlinier dengan menggunakan fungsi aktivasi Gaussian pada lapisan tersembunyi sebelum diproses secara linier di lapisan *output*. RBFNN merupakan salah satu metode yang baik digunakan pada peramalan kunjungan wisatawan karena dapat memberikan nilai akurasi yang tinggi. Kecepatan proses pelatihan jaringan sangat diperlukan, oleh karena itu perlu dilakukan berbagai kombinasi fungsi pelatihan untuk mempercepat konvergensi pelatihan jaringan. Pada penelitian ini model RBFNN dikembangkan dengan kombinasi fungsi pelatihan *levenberg-marquardt* (*trainlm*), *gradient descent with momentum and adaptive learning rate* (*traingdx*) dan regulasi bayesian (*trainbr*). Penelitian ini menggunakan data kunjungan wisatawan mancanegara di Indonesia dari bulan Januari 2008 hingga Januari 2020 dan jumlah kunjungan wisatawan sebagai variabel *input*. Arsitektur jaringan metode RBFNN menggunakan 2 neuron pada *input layer*, 8 neuron pada *hidden layer*, dan 1 neuron pada *output layer* dengan nilai *spread* 1. Hasil menunjukkan bahwa model terbaik untuk peramalan kunjungan wisatawan menggunakan fungsi pelatihan *levenberg-marquardt* (*trainlm*). Nilai MSE pelatihan diperoleh sebesar 0,0088 dengan kecepatan konvergensi pelatihan selama 1 menit 16 detik dan nilai MAPE pengujian sebesar 5,2559% dengan akurasi jaringan sebesar 94,7441%.

Kata kunci:

Radial Basis Function, Peramalan, Wisatawan, Jaringan Syaraf Tiruan

© 2023 Dipublikasikan oleh Jurusan Matematika, Universitas Negeri Semarang

1. Pendahuluan

Pariwisata merupakan komoditas ekspor yang sangat berpengaruh bagi perekonomian. Pariwisata dapat membantu meningkatkan pendapatan karena pariwisata merupakan salah satu sumber penerimaan devisa negara khususnya dibidang ekonomi (Herawati, 2016). Jumlah kunjungan wisatawan mancanegara dari tahun 2020 tercatat mencapai sebesar 4,05 juta kunjungan, jika dibandingkan dengan tahun 2019 jumlah kunjungan mengalami penurunan sebesar 75,03% (BPS, 2021). Peramalan bertujuan untuk perancangan kebijakan yang efektif dimasa mendatang. Metode statistika non-parametrik yang dapat digunakan untuk mengestimasi data tanpa harus memenuhi suatu asumsi yaitu salah satunya *neural network* (Tarigan et al., 2018). *Neural network* merupakan salah satu metode yang dapat digunakan untuk melakukan peramalan.

Radial Basis Function merupakan pengembangan dari *feedforward neural network*. Jaringan RBF terdiri dari tiga lapisan, yaitu lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*) dan lapisan keluaran (*output layer*) (Hashemi et al., 2018). Setiap node pada *hidden layer* mengaktifkan fungsi aktivasi secara non-linier pada vektor masukan dengan fungsi radial basis. Pada *hidden layer* mentransformasikan *input* secara non-linier dan kemudian pada *output layer* menerima sinyal *output* dari *hidden layer* dan diproses secara linier (Du & Swamy, 2014). RBFNN memiliki struktur jaringan yang mudah namun

To cite this article:

Ambarwati, I. (2023). Metode *Radial Basis Function Neural Network* (RBFNN) untuk Peramalan Kunjungan Wisatawan dengan Perbandingan Kombinasi Fungsi Pelatihan. *PRISMA, Prosiding Seminar Nasional Matematika* 6, 687-693.

kemampuan konvergensi yang sangat cepat serta kemampuan pendekatan non-linier yang sangat tinggi (Chen et al., 2019). Terdapat dua fungsi yang dapat digunakan untuk membangun suatu jaringan syaraf basis radial yaitu menggunakan *newrbe* dan *newrb* (Tarigan et al., 2018). Fungsi *newrbe* dan *newrb* disebut fungsi basis karena dapat mengekspansikan segala fungsi lainnya ke dalam fungsi tersebut, sehingga fungsi basis merupakan fungsi yang lengkap (Wiyanti & Pulungan, 2014).

Jaringan syaraf *Radial Basis Function* (RBFNN) dapat diterapkan untuk peramalan kunjungan wisatawan dan memberikan nilai akurasi yang tinggi, meskipun metode ini memiliki kemampuan konvergensi yang cepat namun pada penerapannya masih menghasilkan nilai *error* yang tinggi. Oleh karena itu diperlukan algoritma fungsi pelatihan untuk mempercepat konvergensi dengan menghasilkan nilai MAPE dan MSE yang minimum.

Beberapa penelitian yang sudah dilakukan menggunakan metode RBF yaitu Wulandari & Wahyuningsih (2017) tentang Peramalan Harga Minyak Mentah Dunia (*Crude Oil*) Menggunakan Metode *Radial Basis Function Neural Network* (RBFNN). Peramalan minyak mentah dunia sangat penting bagi sektor pemerintah maupun badan usaha. metode RBFNN digunakan untuk menentukan model terbaik dan juga peramalan dengan menentukan *input* jaringan dan jumlah *hidden layer* dengan metode *cluster K-Means* (Wulandari & Wahyuningsih, 2017).

Penelitian Hapsari et al., (2016) tentang Optimasi *Radial Basis Function Neural Network* Menggunakan *Hybrid Particle Swarm Optimization* dan *Genetic Algorithm* untuk Peramalan Curah Hujan. Peramalan curah hujan sangat dibutuhkan dalam penentuan kalender tanam. Penggunaan metode RBF sangat kompleks sehingga sulit mencari parameter yang sesuai. Cara yang dilakukan untuk pengoptimalan menggunakan *Radial Basis Function Neural Network* (RBF-NN) dengan *Hybrid Particle Swarm Optimization* dan *Genetic Algorithm* (HPSOGA) untuk menentukan parameter yang optimal dari RBF (Hapsari et al., 2016).

1.1. Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan adalah pemrosesan suatu informasi yang terinspirasi dari sistem sel syaraf biologi yang tersusun dari sel-sel syaraf (*neuron*) (Tarigan et al., 2018). Jaringan syaraf tiruan dapat digunakan dalam penyelesaian masalah peramalan, klasifikasi, pengenalan pola serta untuk melakukan pembelajaran (Talahatu et al., 2015). Jaringan syaraf tiruan didefinisikan dengan parameter yaitu neuron sebagai node dari jaringan syaraf, koneksi antar neuron yang menjelaskan topologi dari jaringan syaraf dan algoritma pembelajaran untuk melatih jaringan yang diklasifikasikan dalam tiga kelompok yaitu *supervised learning*, *unsupervised learning* dan *reinforcement learning* (Shanmuganathan & Samarasinghe, 2016).

1.2. Jaringan Layar Jamak

Jaringan layar jamak merupakan arsitektur jaringan syaraf tiruan dengan jumlah lapisan tersembunyi sebanyak satu atau lebih. Jaringan ini memiliki *layer* tambahan yang terletak diantara *layer input* dan *layer output*. Jaringan layar jamak memiliki satu lapisan atau lebih lapisan, sehingga jaringan ini dapat menyelesaikan masalah yang sulit dibanding jaringan dengan lapisan tunggal, namun jaringan ini membutuhkan waktu yang lama dalam proses pelatihan jaringan.

1.3. Feedforward Network

Jaringan *feedforward* memiliki koneksi menuju lapisan tersembunyi pertama yang diorientasikan dari neuron *input* menuju neuron perantara dimana koneksi neuron menuju asal *output*. Jaringan *feedforward* merupakan koneksi yang menuju ke depan atau koneksi antar nodenya tidak membentuk sebuah siklus (Caselli et al., 2008). Struktur jaringan *feedforward* direpresentasikan sebagai berikut.

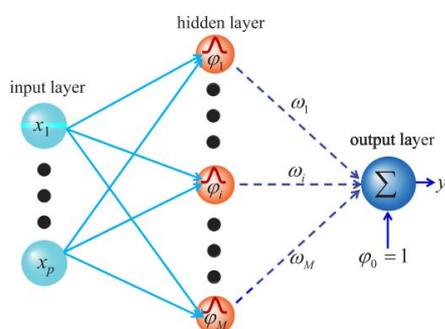
$$z_j = \sum_{i=1}^n w_{ij}u_i - b_j \quad (1)$$

dimana w_{ij} adalah bobot *input*, u_i adalah *input* neuron ke j , dan b_i adalah bias neuron ke j .

1.4. Radial Basis Function

Radial Basis Function Neural Network adalah model *neural network* yang mentransformasikan *input* secara non-linier menggunakan fungsi aktivasi Gaussian pada lapisan tersembunyi sebelum diproses secara linier pada lapisan *output*. *Radial Basis Function Neural Network* (RBFNN) memuat tiga lapisan yaitu lapisan *input* (*input layer*), lapisan tersembunyi (*hidden layer*) dan lapisan keluaran (*output layer*) (Arifiana et al., 2017). *Input layer* menyampaikan koordinat dari *vector input* ke masing-masing unit di *hidden layer*. Setiap unit di *hidden layer* kemudian menghasilkan aktivasi berdasarkan hubungan RBF. Selain itu setiap unit

pada *output layer* akan menghitung kombinasi linier fungsi aktivasi dari unit tersembunyi. Arsitektur *radial basis function* dapat dilihat pada Gambar 1.



(Sumber: Zhao, 2019)

Gambar 1. Arsitektur radial basis function

Parameter yang digunakan dalam RBFNN adalah nilai pusat, spread fungsi basis pada *hidden layer* dan nilai bobot pada *output layer*. Untuk menghasilkan aproksimasi fungsi yang baik, maka nilai spread harus semakin besar. Nilai spread yang besar berarti terdapat banyak neuron yang dibutuhkan untuk menyesuaikan fungsi yang berubah-ubah dengan cepat (Hemageetha & Nasira, 2013). *Output* model pembelajaran RBFNN dapat dirumuskan sebagai berikut (Du & Swamy, 2014).

$$F(x) = \sum_{k=1}^m w_{ki} \theta(\|x - a_k\|) \quad (2)$$

dengan w_{ki} adalah bobot terhubung, a_k adalah pusat RBF, θ adalah fungsi Gaussian, dan m adalah banyaknya unit yang akan dihitung.

1.5. Algoritma Fungsi Pelatihan

Algoritma fungsi pelatihan digunakan untuk mengatur nilai bobot sehingga diperoleh nilai bobot terbaik pada proses akhir pelatihan. Beberapa metode pelatihan jaringan yaitu:

1.5.1 Gradient Descent with Momentum and Adaptive Learning Rate (traingdx)

Traingdx merupakan fungsi pelatihan dengan mengombinasikan pembelajaran adapif *learning rate* dengan penambahan momentum untuk memperbaiki bobot-bobot. Besarnya *learning rate* sangat mempengaruhi kinerja suatu algoritma, *learning rate* yang semakin besar atau kecil menyebabkan pelatihan menjadi lambat. Fungsi traingdx memiliki kecepatan pelatihan yang tinggi sehingga dipakai sebagai *default* dalam pelatihan. Persamaan algoritma ini sebagai berikut.

$$\Delta w_k = p \cdot \Delta w_{k-1} + a \cdot p \cdot \frac{\Delta E_k}{\Delta w_k} \quad (3)$$

p adalah konstanta momentum, w_{k-1} adalah perubahan bobot pada data ke $k - 1$, a adalah konstanta *learning rate* dan E_k adalah performa pada data ke k .

1.5.2 Levenberg-Marquardt (rainlm)

Trainlm merupakan fungsi pelatihan jaringan yang memperbarui bobot dan bias berdasarkan optimasi Levenberg-Marquardt. Proses perubahan bobot dan bias pada algoritma ini menggunakan pendekatan matriks Hessian (H) dengan persamaan berikut.

$$H = J^T J \quad (4)$$

Dan gradient dapat dihitung menggunakan persamaan.

$$g = J^T e \quad (5)$$

J adalah matriks Jacobian yang berisi turunan pertama dari kesalahan jaringan sehubungan dengan bobot dan bias, dan e adalah vector kesalahan jaringan. Perbaikan pembobotan menggunakan persamaan.

$$W = W + [J^T J + \mu I]^{-1} J^T e \quad (6)$$

W adalah fungsi bobot-bobot jaringan dan bias, μ adalah konstanta *learning*, dan I adalah matriks identitas.

1.5.3 Regulasi Bayesian (trainbr)

Trainbr merupakan fungsi pelatihan jaringan yang memperbarui bobot dan nilai bias untuk meningkatkan proses generalisasi. Fungsi pelatihan ini meminimalkan kombinasi kesalahan kuadrat dan bobot kemudian menentukan kombinasi yang benar sehingga menghasilkan jaringan dengan generalisasi yang baik. Proses

ini disebut regularisasi Bayesian. Metode regulasi merubah kinerja kesalahan fungsi dengan menambahkan standar deviasi dari bobot dan bias dengan perumusan sebagai berikut.

$$F = \beta E_d + \alpha E_w \quad (7)$$

Dimana α dan β adalah parameter regulasi, E_d dan E_w didefinisikan sebagai.

$$E_d = \sum_{i=1}^n (t_i - o_i)^2 \quad (8)$$

$$E_w = \frac{1}{n} \sum_{i=1}^n (W_i)^2 \quad (9)$$

n adalah jumlah *input* pada *training* set, t_i adalah nilai target pada data ke- i , o_i adalah *output* untuk data ke- i dan W_i adalah bobot atau batas ambang.

2. Metode

2.1. Pengumpulan Data

Mengumpulkan data historis jumlah kunjungan wisatawan mancanegara ke Indonesia dari bulan Januari 2008 hingga bulan Januari 2020. Data diperoleh dari situs resmi Badan Pusat Statistik (BPS) yang dapat diakses secara *online* melalui laman <https://www.bps.go.id/>.

2.2. Studi Pustaka

Studi pustaka digunakan untuk mencari sumber informasi yang relevan yang dapat memberikan informasi yang diperlukan untuk penelitian. Penelaahan dari sumber-sumber pustaka dijadikan sebagai landasan untuk menganalisis permasalahan yang memuat model jaringan syaraf tiruan, model jaringan syaraf *Radial Basis*, dan algoritma pelatihan jaringan.

2.3. Proses Radial Basis Function Neural Network

Metode *Radial Basis Function Neural Network* digunakan untuk meramalkan kunjungan wisatawan, dalam membangun arsitektur jaringan syaraf tiruan *Radial Basis Function* diterapkan dengan bantuan *software* MATLAB R2011a dalam proses analisisnya. Tahapan yang dilakukan dalam pembentukan model RBF antara lain.

2.3.1. Tahap Awal

Pada tahap awal dilakukan *input* data yang sudah dilakukan proses analisis penentuan data *input* dan data target yang selanjutnya dilakukan normalisasi data. Data yang *diinputkan* kemudian dibagi menjadi data *training* dan data *testing*. Setelah dilakukan pembagian data kemudian menentukan parameter jaringan yaitu jumlah neuron *hidden layer*, nilai spread, target *error* dan maksimum *epoch*.

2.3.2. Tahap Pelatihan

Pada tahap pelatihan dilakukan dengan *menginputkan* data *training* yang telah dinormalisasi. Pada proses ini terjadi pengenalan pola-pola data untuk mendapat nilai bobot yang dapat memetakan antara data *input* dengan data target yang diinginkan. Kemudian melakukan proses pelatihan jaringan dengan kombinasi fungsi pelatihan *traingdx*, *trainlm*, dan *trainbr*. Hasil dari proses pelatihan ini adalah pembaruan bobot yang akan digunakan dalam proses pengujian.

2.3.3. Tahap Pengujian

Pada tahap pengujian, jaringan yang sudah dilatih pada proses pelatihan data dengan parameter yang telah ditentukan, akan diperoleh nilai bobot yang kemudian digunakan untuk mengolah data *testing* sehingga menghasilkan *output* sesuai yang diharapkan. Berdasarkan nilai MAPE yang dihasilkan dapat digunakan untuk mengetahui apakah jaringan dapat bekerja dengan baik dalam meramalkan pola. Analisis selanjutnya membandingkan hasil simulasi jaringan dengan data aktual untuk dipilih model dengan fungsi pelatihan terbaik yang menghasilkan *error* terkecil.

3. Hasil dan Pembahasan

Langkah-langkah pemodelan *Radial Basis Function* (RBFNN) untuk peramalan kunjungan wisatawan dengan kombinasi fungsi pelatihan antara lain.

3.1. Menentukan Input dan Target Jaringan

Lag-lag yang signifikan pada plot PACF dijadikan sebagai komponen data *input*. Dengan demikian diperoleh dua variabel *input* yaitu lag 1 dan lag 2, sehingga jaringan yang dibangun memiliki dua *input*

x_{t-1} dan x_{t-2} dengan target x_t . Banyak data yang digunakan sebanyak 143 data, dengan pembagian komposisi data 50%:50%, yaitu data *training* sebanyak 72 data dan data *testing* sebanyak 71 data.

3.2. Normalisasi Data

Sebelum data diinputkan ke jaringan, data-data dinormalisasi terlebih dahulu sehingga menjadi data yang berada dalam rentang 0 sampai 1. Rumus normalisasi yang digunakan sebagai berikut.

$$a = \min(\min(\text{inputlatih}));$$

$$b = \max(\max(\text{inputlatih}));$$

$$p = ((\text{inputlatih} - a) / (b - a));$$

3.3. Pembentukan Arsitektur RBFNN

Membangun model jaringan *Radial Basis Function* untuk peramalan pada Matlab dapat menggunakan perintah fungsi berikut.

```
net = newrb(X,T,GOAL,SPREAD,MN,DF);
```

pembentukan model RBFNN terbaik dilakukan dengan menggunakan langkah-langkah sebagai berikut.

3.3.1 Menentukan Algoritma Pelatihan

Algoritma pelatihan pada Matlab yang digunakan untuk membangun jaringan yaitu *levenberg-marquardt* (*trainlm*), *gradient descent with momentum and adaptive learning rate* (*traingdx*) dan regulasi bayesian (*trainbr*). Pemilihan algoritma pelatihan digunakan untuk mengetahui arsitektur jaringan RBF yang menghasilkan nilai *error* terkecil dengan melakukan *trial and error*

3.3.2 Penentuan Parameter Jaringan

Rancangan model jaringan yang akan dibangun dimulai dengan menginisialisasi parameter jaringan. Parameter yang digunakan untuk pelatihan jaringan dapat dilihat pada Tabel 1.

Tabel 1. Parameter jaringan RBFNN

Maksimum <i>epoch</i>	: 3000
Target <i>error</i> (goal)	: 0.001
Spread	: 1
Neuron tersembunyi	: 8
Fungsi Pelatihan	: <i>trainlm</i> , <i>traingdx</i> , <i>trainbr</i>

3.3.3 Denormalisasi Data

Mengubah data hasil peramalan jaringan syaraf tiruan yang memiliki range 0 sampai 1 menjadi nilai aslinya. Hasil simulasi prediksi jaringan dari proses pelatihan yang ternormalisasi dikembalikan lagi seperti semula. Perintah untuk denormalisasi data *output* pelatihan sebagai berikut.

$$\text{hasil_latih} = ((\text{output_latih}) * (b - a)) + a;$$

3.4. Pemilihan Model Terbaik

Pemilihan model RBFNN terbaik dengan kombinasi fungsi pelatihan dapat dilihat melalui langkah-langkah berikut.

3.4.1 Pelatihan Jaringan

Pelatihan jaringan dilakukan dengan kombinasi fungsi pelatihan yaitu *trainlm*, *traingdx*, dan *trainbr*. Hasil pelatihan jaringan dengan kombinasi algoritma pelatihan dapat dilihat pada Tabel 2.

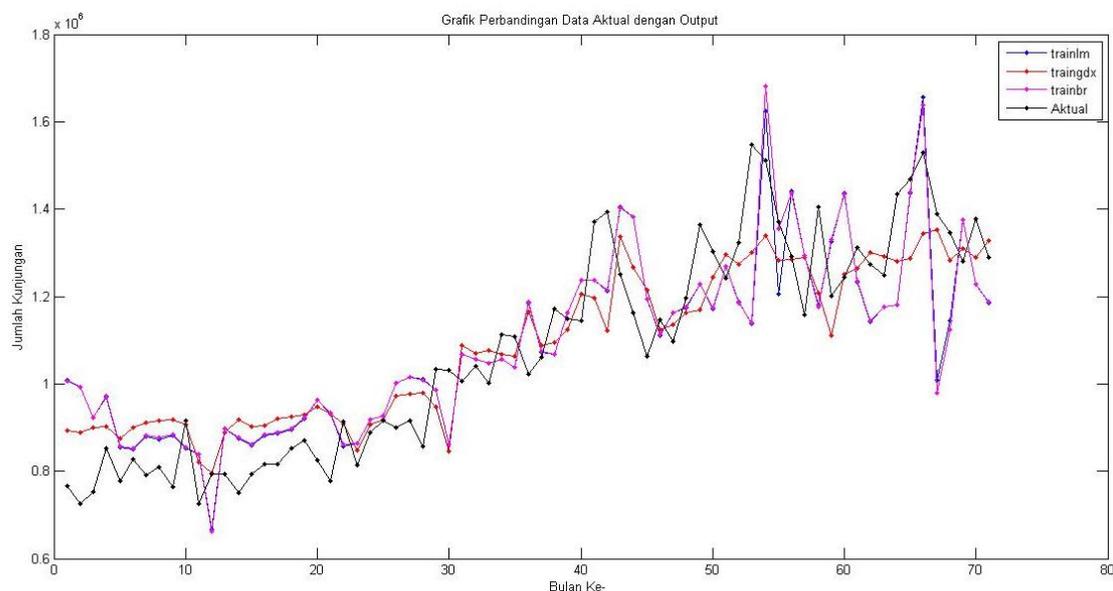
Tabel 2. Hasil MSE dan MAPE pelatihan jaringan

Fungsi Pelatihan	MSE	MAPE (%)	Epoch	Waktu
<i>trainlm</i>	0,0088	5,1879	3000	1 menit 16 detik
<i>traingdx</i>	0,0124	6,0574	3000	48 detik
<i>trainbr</i>	0,0089	5,2031	3000	1 menit 26 detik

Berdasarkan Tabel 2 diperoleh bahwa hasil pelatihan jaringan menggunakan kombinasi fungsi pelatihan dengan nilai MSE pelatihan terkecil didapatkan sebesar 0,0088 pada fungsi pelatihan *trainlm* dengan kecepatan konvergensi selama 1 menit 16 detik.

3.4.2 Pengujian Jaringan

Pada proses pengujian, hasil jaringan yang sudah dilatih pada tahap pelatihan kemudian diujikan menggunakan data *testing*. Pengujian jaringan untuk memvalidasi dan melihat presentase keakuratan suatu jaringan yang dirancang dengan melihat nilai MAPE. Hasil perbandingan data aktual dengan *output* jaringan menggunakan kombinasi fungsi pelatihan *trainlm*, *traingdx* dan *trainbr* dapat dilihat pada Gambar 2.



Gambar 2. Grafik perbandingan data aktual dengan output jaringan

Berdasarkan Gambar 2 menunjukkan bahwa fungsi pelatihan *trainlm* memberikan nilai yang paling mendekati data aktual dengan nilai MAPE sebesar 5,2559% yang selengkapnya dapat dilihat pada Tabel 3.

Tabel 3. Hasil MSE, MAPE dan akurasi jaringan

Fungsi Pelatihan	MSE	MAPE (%)	Akurasi
<i>trainlm</i>	0,0089	5,2559	94,7441%
<i>traingdx</i>	0,0126	6,1427	93,8573%
<i>trainbr</i>	0.0091	5,2764	94,7236%

Pemilihan fungsi pelatihan terbaik berdasarkan nilai MAPE terkecil yang dihasilkan pada tahap pengujian. Pada Tabel 3 menunjukkan bahwa fungsi pelatihan *trainlm* menghasilkan nilai MAPE pengujian terkecil yaitu sebesar 5,2559% dan nilai MSE pengujian sebesar 0,0089 dengan akurasi jaringan sebesar 94,7441%. Hal ini menunjukkan bahwa metode *Radial Basis Function Neural Network* (RBFNN) dengan fungsi pelatihan *levenberg-marquardt* (*trainlm*) dapat mengurangi nilai *error* pada peramalan kunjungan wisatawan.

4. Simpulan

Pada penelitian ini dilakukan kombinasi fungsi pelatihan jaringan agar diperoleh fungsi pelatihan yang memberikan hasil optimal untuk diterapkan pada peramalan wisatawan. Berdasarkan hasil penelitian dan pembahasan metode di atas dapat disimpulkan bahwa metode yang dirancang dengan kombinasi fungsi pelatihan diperoleh model terbaik dengan 2 neuron pada lapisan input, 8 neuron pada lapisan tersembunyi, 1 neuron pada lapisan output, nilai spread 1, menggunakan algoritma fungsi pelatihan *levenberg-marquardt* (*trainlm*) dengan nilai MSE pelatihan sebesar 0,0088 dan nilai MAPE pengujian sebesar 5,2559%. Kecepatan konvergensi pelatihan selama 1 menit 16 detik dengan akurasi jaringan sebesar 94,7441%.

Daftar Pustaka

- Arifiana, G., Anggraeni, N., & Abadi, A. M. (2017). Prediksi Nilai Indeks Harga Konsumen (IHK) Kota Jambi Menggunakan Radial Basis Function Neural Network (RBFNN) dengan Metode Fuzzy C-Means Clustering. *Prosiding Seminar Matematika Dan Pendidikan Matematika*. Yogyakarta.
- BPS. (2021). Berita Resmi Statistik 1 Februari 2021. (Online). (<https://www.bps.go.id/pressrelease/2021/02/01/1796/jumlah-kunjungan-wisman-ke-indonesia-bulan-desember-2020-mencapai-164-09-ribu-kunjungan-.html>, diakses 25 September 2022).
- Caselli, M., Trizio, L., Gennaro, G., & Ielpo, P. (2008). A Simple Feedforward Neural Network for the PM10 Forecasting : Comparison with a Radial Basis Function Network and a Multivariate Linear Regression Model. *Water,Air, Soil ,Pollut*, 201(1), 365–377.
- Chen, Y., Yu, G., Long, Y., Teng, J., You, X., Liao, B., & Lin, H. (2019). Bioresource Technology Application of radial basis function artificial neural network to quantify interfacial energies related to membrane fouling in a membrane bioreactor. *Bioresource Technology*, 293, 122103.
- Du, K. ., & Swamy, M. (2014). Radial Basis Function Networks. *In Du,K.L Swamy,M*.
- Hapsari, K., Cholissodin, I., & Santoso, E. (2016). Optimasi Radial Basis Function Neural Network Menggunakan Hybrid Particle Swarm Optimization Dan Genetic Algorithm Untuk Peramalan Curah. *Jurnal Mahasiswa PTIIK*, 7(15).
- Hashemi, A., Madanifar, F., & Abbasi, M. (2018). Implementation of multilayer perceptron (MLP) and radial basis function (RBF) neural networks to predict solution gas-oil ratio of crude oil systems. *Petroleum, December*, 0–1.
- Hemageetha, N., & Nasira, G. . (2013). Radial Basis Function Model for Vegetabel Price Prediction. *Proceedings of the 2013 International Conference on Pattern Recognition, Informatics and Mobile Engineering* (pp. 424-428). IEEE.
- Herawati, S. (2016). Peramalan Kunjungan Wisatawan Mancanegara Menggunakan Generalized Regression Neural Networks. *Infote Journal*, 8(1), 35–39.
- Shanmuganathan, S., & Samarasinghe, S. (2016). *Artificial Neural Network Modelling*. Springer.
- Talahatu, J., Benarkah, N., & Jimmy. (2015). Penggunaan Aplikasi Sistem Jaringan Syaraf Tiruan Berulang Elman Untuk Prediksi Pergerakan Harga Saham. *Jurnal Ilmiah Mahasiswa Universitas Surabaya*, 4(1), 1–12.
- Tarigan, R., Yasin, H., & Prahutama, A. (2018). Peramalan Indeks Harga Saham Gabungan (Ihsg) Dengan Metode Radial Basis Function Neural Network Menggunakan Gui Matlab. *Jurnal Gaussian*, 7(4), 431–442.
- Wiyanti, D. T., & Pulungan, R. (2014). RBF and ARIMA Combined for Time Series Forecasting. *Seminar Nasional Aplikasi Teknologi Informasi (SNATI)*, 1(1).
- Wulandari, A., & Wahyuningsih, S. (2017). Peramalan Harga Minyak Mentah Dunia (Crude Oil) Menggunakan Metode Radial Basis Function Neural Network (RBFNN) Crude Oil Price Forecasting Using Radial Basis Function Neural Network Method (RBFNN). *Jurnal Eksponensial*, 8(2), 161–168.
- Zhao, Z., Lou, Y., Chen, Y., Lin, H., Li, R., & Yu, G. (2019). Bioresource Technology Prediction of Interfacial Interactions Related with Membrane Fouling in A Membrane Bioreactor Based on Radial Basis Function Artificial Neural Network (ANN). *Bioresource Technology*, 282, 262–268.