

Model *Radial Basis Function Neural Network* (RBFNN) untuk Meramalkan Jumlah Penumpang Kereta Api di Jabodetabek

Risyana Nur Aliyyah*, Anneke Iswani Achmad

Prodi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Islam Bandung, Indonesia.

*risyana09@gmail.com, annekeiswani11@gmail.com

Abstract. Forecasting is a technique for predicting data in the future by paying attention to past data and current data. One method that is quite well known in time series forecasting is the Auto Regressive Integrated Moving Average (ARIMA). ARIMA forecasting method must pay attention to the data pattern and data stationarity, where the data must be stationary in the mean and variance. On the other hand, there is one method that does not take into account the data pattern, namely the Radial Basis Function Neural Network (RBFNN). This RBFNN method can be used to get more efficient forecasting results, because there is no need to make the data stationary. In this thesis, the data used is data on the number of train passengers in Jabodetabek in 2014-2020. Where the train is one of the economic sources in the transportation sector which has experienced a drastic decrease in the number of passengers, this will certainly have an impact on income which also decreases. The results of the analysis of the RBFNN model with a network structure consisting of 1 input neuron, 3 hidden neurons, and 1 output neuron resulted in a MAPE value of 41,77% and obtained forecasting results for January 2021 as many as 14237 thousand people. This model is used to estimate the number of train passengers for the next 11 months.

Keywords: Forecasting, ARIMA, RBFNN, Train Passengers.

Abstrak. Peramalan merupakan teknik untuk memprediksi suatu data pada masa yang akan datang dengan memperhatikan data masa lalu maupun data pada saat ini. Salah satu metode yang cukup terkenal dalam peramalan *time series* yaitu *Auto Regressive Integrated Moving Average* (ARIMA). Metode peramalan ARIMA harus memperhatikan pola data dan stasioneritas data, dimana data harus stasioner dalam rata-rata dan varians. Disisi lain, ada salah satu metode yang tidak memperhitungkan pola data, yaitu *Radial Basis Function Neural Network* (RBFNN). Metode RBFNN ini bisa digunakan untuk mendapatkan hasil peramalan yang lebih efisien, karena tidak perlu membuat data menjadi stasioner. Pada penelitian ini, data yang digunakan yaitu data jumlah penumpang kereta api di Jabodetabek tahun 2014-2020. Dimana kereta api merupakan salah satu sumber perekonomian bidang transportasi yang mengalami penurunan jumlah penumpang secara drastis, hal ini tentunya akan berdampak terhadap pendapatan yang juga menurun. Hasil analisis model RBFNN dengan struktur jaringan yang terdiri dari 1 *neuron input*, 3 *neuron tersembunyi*, dan 1 *neuron output* menghasilkan nilai MAPE sebesar 41,77% serta diperoleh hasil peramalan untuk bulan Januari 2021 sebanyak 14237 ribu orang. Model ini digunakan untuk meramalkan jumlah penumpang kereta api untuk 11 bulan berikutnya.

Kata Kunci: Peramalan, ARIMA, RBFNN, Penumpang Kereta Api.

1. Pendahuluan

Peramalan (*forecasting*) merupakan teknik untuk memprediksikan suatu nilai pada masa yang akan datang dengan memperhatikan data masa lalu maupun data pada saat ini. Salah satu metode peramalan yang banyak dikembangkan saat ini adalah *time series*. *Time series* atau runtun waktu

adalah himpunan observasi data terurut dalam waktu. Metode runtun waktu adalah metode peramalan dengan menggunakan analisa pola hubungan antar variabel yang akan diperkirakan dengan variabel waktu. Peramalan suatu data runtun waktu perlu memperhatikan tipe atau pola data. Salah satu metode yang cukup terkenal dalam peramalan *time series* yaitu ARIMA (*Auto Regressive Integrated Moving Average*).

ARIMA adalah suatu metode yang menghasilkan ramalan-ramalan berdasarkan pola data secara historis. Model ARIMA merupakan gabungan antara model AR (Autoregressive) yaitu suatu model yang menjelaskan pergerakan suatu variabel melalui variabel itu sendiri di masa lalu dan model MA (Moving Average) yaitu model yang melihat pergerakan variabelnya melalui residualnya di masa lalu (Lilipaly dkk, 2014). Metode peramalan ARIMA harus memperhatikan pola data dan stasioneritas data, dimana data harus stasioner dalam rata-rata dan varians. sehingga menimbulkan pertanyaan apakah pola data dan stasioneritas data sudah sesuai. Disisi lain, ada salah satu metode yang tidak memperhitungkan stasioneritas data, yaitu *Radial Basis Function Neural Network* (RBFNN).

Jaringan *Radial Basis Function Neural Network* (RBFNN) adalah salah satu pembelajaran yang biasa digunakan untuk penyelesaian masalah *forecasting* (Palit & Popavic, 2005). RBFNN digunakan untuk menyelesaikan permasalahan komponen non stasioner dan non linier. Model RBFNN terdiri dari 3 lapisan, yaitu lapisan masukan (*input*), lapisan tersembunyi (*hidden*), dan lapisan keluaran (*output*). RBFNN memiliki bobot pada jaringan yang terhubung dari lapisan *hidden* ke lapisan *output*, terdapat fungsi aktivasi pada lapisan *hidden* dan mengeluarkan nilai berupa persamaan nonlinear, sedangkan pada lapisan *output* atau akhir proses RBFNN mengeluarkan nilai berupa persamaan linear (Palit & Popavic, 2005).

RBFNN digunakan untuk menyelesaikan permasalahan komponen non stasioner dan non linier. Peneliti menggunakan metode RBFNN terhadap data jumlah penumpang kereta api. Daerah yang memiliki jumlah penumpang kereta api terbanyak adalah Jabodetabek. Pada tahun 2016-2019, jumlah penumpang kereta api di Jabodetabek cenderung meningkat, namun memasuki tahun 2020 jumlah penumpang kereta api di Jabodetabek mengalami penurunan yang sangat drastis. Menurunnya jumlah penumpang akan mengakibatkan pendapatan yang juga menurun. Oleh karena itu, perusahaan membutuhkan peramalan jumlah penumpang sebagai upaya perencanaan program berikutnya dengan tujuan untuk meningkatkan pendapatan.

Berdasarkan latar belakang yang telah diuraikan, maka rumusan masalah dalam penelitian ini, yaitu “Bagaimana hasil peramalan untuk banyaknya jumlah penumpang kereta api di Jabodetabek menggunakan model *Radial Basis Function Neural Network* (RBFNN)?”. Selanjutnya, tujuan dalam penelitian ini diuraikan dalam pokok-pokok sebagai berikut :

1. Untuk mendapatkan jumlah *neuron* pada lapisan *input*.
2. Untuk mendapatkan jumlah *neuron* pada lapisan tersembunyi.
3. Untuk mendapatkan model *Radial Basis Function Neural Network* (RBFNN) pada data deret waktu (*time series*).
4. Untuk mengetahui tingkat akurasi model *Radial Basis Function Neural Network* (RBFNN) dalam peramalan.
5. Untuk mendapatkan peramalan banyaknya jumlah penumpang kereta api di Jabodetabek menggunakan model *Radial Basis Function Neural Network* (RBFNN).

2. Metodologi

Data

Data yang digunakan pada penelitian ini adalah data sekunder yang diperoleh dari Badan Pusat Statistik (BPS). Data tersebut merupakan data *time series* jumlah penumpang kereta api di Jabodetabek dari januari 2014 sampai desember 2020 dengan data pengamatan sebanyak 84 pengamatan, sebagai berikut :

Tabel 1. Data Jumlah Penumpang Kereta api di Jabodetabek

Periode Januari 2014-Desember 2020

Tahun	Bulan	Jumlah Penumpang
2014	Jan-14	15176
	Feb-14	14856
	Mar-14	17471
.	.	.
.	.	.
2020	Des-20	11330

Metode

Pada Penelitian ini akan digunakan metode *Radial Basis Function Neural Network* (RBFNN) untuk meramalkan jumlah penumpang kereta api di Jabodetabek. Berikut merupakan tahapan peramalan menggunakan RBFNN.

1. Data dinormalisasi menjadi skala 0-1 dengan menggunakan persamaan rumus berikut :

$$x = \frac{y - y^{\min}}{y^{\max} - y^{\min}}$$

dimana :

y = Data asli
 x = Data normalisasi
(Tan dkk, 2012)

2. Menentukan banyaknya lapisan input menggunakan plot PACF terhadap seluruh pengamatn dengan melihat lag yang signifikan. Plot PACF diperoleh dari *software* Minitab.
3. Data dibagi menjadi 2, yaitu training dan testing. Komposisi yang peneliti gunakan adalah 80% untuk data training dan 20% untuk data testing
4. Menentukan banyaknya lapisan tersembunyi menggunakan metode *trial and error* dengan menggunakan 2 sampai 10 *cluster*. Pengklusteran data dilakukan dengan menggunakan metode *K-means cluster* yang dihasilkan dengan bantuan *software* SPSS. Selanjutnya data hasil clustering diproses dengan nilai pusat dan simpangan baku yang menghasilkan nilai *Means Square Error* (MSE) yang dihitung menggunakan persamaan berikut :

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2$$

(Makridakis dkk, 1999)

5. Menghitung Nilai Aktivasi menggunakan persamaan fungsi gaussian sebagai berikut :

$$\phi_{ij} = \phi_j(x_i) = e^{\left(-\frac{(x_i - \mu_j)^2}{2\sigma_j^2}\right)}$$

(Sutijo dkk, 2006)

dimana :

σ_j = nilai simpangan baku pada masing-masing *cluster* ke-j
 x_i = nilai normalisasi vektor input ke-i
 μ_j = nilai pusat *cluster* ke-j

6. Selanjutnya hasil dari perhitungan fungsi gaussian disajikan kedalam matriks gaussian
7. Matriks gaussian digunakan untuk menghitung nilai bobot dan bobot bias dengan persamaan rumus berikut :

$$\hat{w} = (\Phi^T \Phi)^{-1} \Phi^T \hat{y}$$

(Howlett & Jain, 2001)

8. Menghitung nilai output jaringan dengan menggunakan persamaan rumus berikut :

$$y_i = \sum_{j=1}^m w_j \phi_j(x_{i-1}) + w_b$$

(Orr, 1996)

9. Menentukan tingkat akurasi peramalan menggunakan *mean percentage error* (MAPE)

dengan rumus perhitungan berikut :

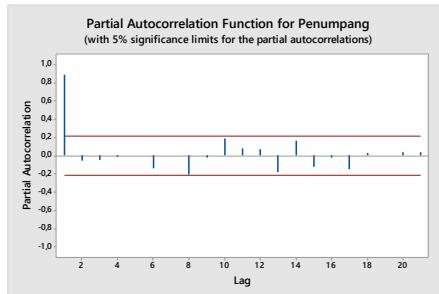
$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \left(\frac{Y_t - F_t}{Y_t} \right) \right| \times 100$$

(Makridakis dkk, 1999)

3. Pembahasan dan Diskusi

Penentuan Lapisan Input

Untuk mengetahui banyaknya *neuron* pada lapisan *input* digunakan plot PACF terhadap seluruh data, dapat dilihat pada gambar berikut :



Gambar 1. Plot PACF Data Jumlah Penumpang Kereta Api di Jabodetabek

Berdasarkan plot PACF pada gambar 2, diketahui bahwa lag yang signifikan berada pada *lag* 1. Maka dari itu, banyaknya *neuron* pada lapisan *input* adalah 1.

Penentuan Lapisan Tersembunyi

Menentukan banyaknya *neuron* pada lapisan tersembunyi dilakukan dengan cara *trial and error* terhadap beberapa model. Model yang digunakan yaitu model (1-2-1), (1-3-1), (1-4-1), (-1-5-1), (1-6-1), (1-7-1), (-1-8-1), (1-9-1), dan (1-10-1). Proses clustering dilakukan dengan metode *K-Means Cluster* agar dapat diketahui nilai pusat dan simpangan baku setiap *cluster*. berikut ini hasil perhitungan nilai pusat dan simpangan baku untuk 3 cluster.

Tabel 2. Nilai Pusat dan Simpangan Baku *Cluster* 3

Neuron	1	2	3
Nilai Pusat	0,62545	0,21357	0,89671
Simpangan Baku	0,200224	0,462136	0,139143

Pada penelitian ini, model terbaik akan dilihat dari nilai MSE *training* terkecil dengan mempertimbangkan nilai MSE *testing* terkecil. Proses perhitungan dilakukan menggunakan data hasil clustering dengan nilai pusat dan simpangan baku setiap cluster. Berikut merupakan nilai MSE *training* dan MSE *testing* dari masing-masing model.

Tabel 3. Nilai MSE Model RBF

Model	MSE	
	Training	Testing
(1-2-1)	0,0044	0,0882
(1-3-1)	0,0043	0,0515
(1-4-1)	0,0043	0,0722
(1-5-1)	0,0039	0,1282
(1-6-1)	0,0044	0,0948
(1-7-1)	0,0055	0,1605
(1-8-1)	0,0054	0,1212

(1-9-1)	0,0051	0,1515
(1-10-1)	0,0052	0,1650

Berdasarkan hasil *trial and error* pada tabel diatas, nilai MSE terkecil untuk *training* terletak pada kluster 5. Namun model terbaik dipilih dengan mempertimbangkan nilai MSE *testing* terkecil, yaitu terletak pada kluster 3. Dengan demikian banyaknya *neuron* pada lapisan tersembunyi adalah 3.

Menghitung Nilai Aktivasi

Nilai fungsi aktivasi dihitung menggunakan rumus persamaan fungsi gaussian, berikut contoh perhitungannya :

$$\phi_1(x_1) = e^{-\frac{(x_1 - \mu_1)^2}{2\sigma_1^2}}$$

$$\phi_1(x_1) = e^{-\frac{(0,409912 - 0,62545)^2}{2(0,200224)^2}} = 0,3138567746$$

Selanjutnya perhitungan tersebut disajikan dalam matriks, dalam hal ini akan didapat matriks gaussian berordo 66x3.

Menghitung nilai bobot dan bobot bias

Pada perhitungan ini dibutuhkan matriks gaussian yang diperoleh pada perhitungan fungsi aktivasi, dan ditambahkan satu kolom bernilai 1 sebagai bobot bias, menjadi :

$$\phi = \begin{bmatrix} 0,3139 & 0,8348 & 0,0000 & 1,00 \\ 0,2718 & 0,8544 & 0,0000 & 1,00 \\ 0,6882 & 0,6754 & 0,0003 & 1,00 \\ \vdots & \vdots & \vdots & \vdots \\ 0,3112 & 0,1576 & 0,8557 & 1,00 \end{bmatrix}$$

Berikut hasil perhitungan nilai bobot dan bobot bias :

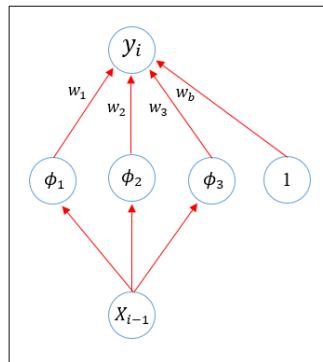
$$\begin{aligned} \hat{w} &= (\Phi^T \Phi)^{-1} \Phi^T y \\ &= \left(\begin{bmatrix} 0,3139 & 0,2718 & \dots & 0,3112 \\ 0,8348 & 0,8544 & \dots & 0,1576 \\ 0,0000 & 0,0000 & \dots & 0,0003 \\ 1 & 1 & \dots & 1 \end{bmatrix} \begin{bmatrix} 0,3139 & 0,8348 & 0,0000 & 1,00 \\ 0,2718 & 0,8544 & 0,0000 & 1,00 \\ 0,6882 & 0,6754 & 0,0003 & 1,00 \\ \vdots & \vdots & \vdots & \vdots \\ 0,3112 & 0,1576 & 0,8557 & 1,00 \end{bmatrix} \right)^{-1} \\ &\quad \times \left(\begin{bmatrix} 0,3139 & 0,2718 & \dots & 0,3112 \\ 0,8348 & 0,8544 & \dots & 0,1576 \\ 0,0000 & 0,0000 & \dots & 0,0003 \\ 1 & 1 & \dots & 1 \end{bmatrix} \begin{bmatrix} 0,409912 \\ 0,396923 \\ \vdots \\ 0,841783 \end{bmatrix} \right) \\ \hat{w} &= \begin{bmatrix} 0,0124 \\ -0,4721 \\ 0,1344 \\ 0,8399 \end{bmatrix} = \begin{pmatrix} w_1 \\ w_2 \\ w_3 \\ w_4 \end{pmatrix} \end{aligned}$$

Tingkat Akurasi Peramalan

Perhitungan dilakukan menggunakan rumus persamaan MAPE, berdasarkan hasil perhitungan tingkat akurasi peramalan menghasilkan nilai MAPE sebesar 41,77% model tersebut termasuk kedalam kriteria cukup baik untuk digunakan dalam meramalkan jumlah penumpang kereta api di Jabodetabek.

Menghitung Nilai Output (Peramalan)

Peramalan banyaknya jumlah penumpang dilakukan menggunakan struktur jaringan dengan 1 *neuron* pada lapisan *input*, 3 *neuron* pada lapisan tersembunyi, dan 1 *neuron* pada lapisan *output* dan dibuat arsitektur RBFNN sebagai berikut :

**Gambar 2.** Arsitektur RBFNN Model (1-3-1)

Diketahui $input x = 0,253805$ ini merupakan data pada bulan Desember 2020. Selanjutnya bobot yang diperoleh pada data hasil *training* yaitu $w_1 = 0,0124$; $w_2 = -0,4721$; $w_3 = 0,1344$; $w_b = 0,8399$. Berdasarkan model RBFNN yang terbentuk, berikut merupakan perhitungan peramalan jumlah penumpang kereta api untuk bulan Januari 2021 :

$$\begin{aligned}
 y_i &= \sum_{j=1}^3 w_j \phi_j(x_{i-1}) + w_b \\
 &= 0,0124\phi_1(x) - 0,4721\phi_2(x) + 0,1344\phi_3(x) + 0,8399 \\
 &= 0,0124(0,178594125) - 0,4721(0,9962172) + 0,1344(0,000023132) + 0,8399 \\
 &= 0,37180353
 \end{aligned}$$

y_i merupakan nilai output berupa hasil peramalan yang skala data nya masih diantara 0-1, selanjutnya hasil ramalan tersebut didenormalisasi ke data asli, berikut perhitungannya :

$$F_t = x_i(y_{max} - y_{min}) + y_{min}$$

$$= 0,37180353 (29714 - 5077) + 5077$$

$$= 14237,12$$

dimana perhitungan $\phi_j(x_{i-1})$ untuk $j = 1, 2, 3$, sebagai berikut :

$$\begin{aligned}
 \phi_1(x_{i-1}) &= \exp\left(-\frac{(x_{i-1} - \mu_1)^2}{2\sigma_1^2}\right) \\
 &= \exp\left(-\frac{(0,253805 - 0,625450574612903)^2}{2(0,200224291862912)^2}\right) \\
 &= 0,178594125
 \end{aligned}$$

$$\phi_2(x_{i-1}) = \exp\left(-\frac{(x_{i-1} - \mu_2)^2}{2\sigma_2^2}\right) = 0,9962172$$

$$\phi_3(x_{i-1}) = \exp\left(-\frac{(x_{i-1} - \mu_3)^2}{2\sigma_3^2}\right) = 0,000023132$$

Dengan cara yang sama dilakukan perhitungan peramalan jumlah penumpang kereta api untuk bulan Februari sampai dengan Desember 2021. Berikut hasil perhitungan ramalan jumlah penumpang kereta api di Jabodetabek :

Tabel 4. Hasil Peramalan Jumlah Penumpang Kereta Api di Jabodetabek

Bulan	Hasil Peramalan
Januari 2021	14237
Februari 2021	14940
Maret 2021	15219
April 2021	15340
Mei 2021	15394
Juni 2021	15419
Juli 2021	15430
Agustus 2021	15435
September 2021	15437
Oktober 2021	15438
November 2021	15439
Desember 2021	15439

4. Kesimpulan

Berdasarkan hasil perhitungan dan pembahasan diperoleh kesimpulan sebagai berikut :

1. Berdasarkan plot PACF, lag yang signifikan berada pada lag pertama yang menunjukkan bahwa jumlah *neuron* pada lapisan *input* yaitu sebanyak 1 *neuron*.
2. Metode *trial and error* dengan perhitungan fungsi gaussian dan K-Means Cluster menghasilkan jumlah *neuron* pada lapisan tersembunyi sebanyak 3 *neuron* dengan nilai MSE terkecil yaitu sebesar 0,0043 untuk data *training* dan 0,0515 untuk data *testing*.
3. Proses pembentukan model *Radial Basis Function Neural Network* (RBFNN) pada data runtun waktu jumlah penumpang kereta api di Jabodetabek memiliki model terbaik dengan struktur jaringan yang terdiri dari 1 *neuron* pada lapisan *input*, 3 *neuron* pada lapisan tersembunyi, dan 1 *neuron* pada *output*.
4. Tingkat akurasi model peramalan RBFNN (1-3-1) dengan nilai MAPE yaitu sebesar 41,77%. Berdasarkan kategori, kemampuan peramalan model RBFNN (1-3-1) cukup baik, karena memiliki nilai MAPE kurang dari 50%.
5. Hasil ramalan jumlah penumpang kereta api di Jabodetabek dengan model RBFNN untuk bulan Januari 2021 sebesar 14327 ribu orang, dan pada bulan-bulan berikutnya ditunjukkan pada tabel 3. Namun karena adanya kondisi pandemi pada tahun 2020, maka ramalan harus disikapi dengan bijak karena tidak ada yang dapat diprediksi atau diramalkan pada masa pandemi.

Acknowledge

Peneliti mengucapkan terima kasih kepada Badan Pusat Statistik yang telah menyediakan data maupun informasi yang lengkap dan jelas serta mudah diakses untuk tujuan penelitian ini. Kepada pihak-pihak yang telah menyediakan referensi sebagai tolak ukur peneliti dalam melakukan pengujian sampai terselesaiannya penelitian ini saya ucapkan terima kasih.

Daftar Pustaka

- [1] Howlett, Robert J. & Jain, Lakhmi. (2001). *Radial Basis Function Networks 2*. Heidelberg: Springer.
- [2] Lilipaly, G. S., Hatidja, D., & Kekenusa, J. S. (2014). Prediksi Harga Saham PT. BRI, Tbk. Menggunakan Metode ARIMA (*Autoregressive Integrated Moving Average*). *Jurnal Ilmiah Sains*, Volume 14, Nomor 2, 61-67.
- [3] Makridakis, S., Wheelwright, S. C., & McGee, V. E. (1999). *Metode dan Aplikasi Peramalan* (Alih Bahasa Untung Sus Andriyanto dan Abdul Basith Edisi Kedua Jilid Satu). Jakarta: Erlangga.
- [4] Orr, M., J., L. (1996). *Introduction to Radial Basis Function Networks*. Scotland : University of Edinburgh..

- [5] Palit, A. K. & Popavic, D. (2005). *Computational Intelligence in Time Series Forecasting*. Glasgow: Springer.
- [6] Sutijo, B., Subanar, & Guritno, S. (2006). Pemilihan Hubungan Input-Node Pada Jaringan Saraf Fungsi Radial Basis. Berkala MIPA. 16, 1.
- [7] Tan, F., Gracianti, G., Susanti, Steven, Lukas, S. (2012). Aplikasi Prediksi Harga Saham Menggunakan Jaringan Syaraf Radial Basis Function dengan Metode Pembelajaran Hybrid. Jurnal Ilmiah Ilmu Komputer, Vol. 8, No. 2, 175-181.
- [8] Shofwani Sheila Ghazia, Kudus Abdul. (2021). *Penentuan Kriteria Pengunjung dalam Pemilihan Green Hotel di Kota Bandung Menggunakan Metode Discrete Choice Experiment dengan Desain Choice Sets Kombinatorial*. Jurnal Riset Statistika, 1(1), 1-9.