

Perbandingan Fungsi Aktivasi Gaussian dan Multikuadratik pada Radial Basis Function Neural Network Untuk Prediksi Indeks Harga Konsumen Di Surabaya

Fiqih Pavita Andharluana¹, Aviolla Terza Damaliana^{*2}, Trimono³

^{1,2,3}Sains Data, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional “Veteran” Jawa Timur, Indonesia

Email: ¹21083010042@student.upnjatim.ac.id, ²aviolla.terza.sada@upnjatim.ac.id,
³trimono.stat@upnjatim.ac.id

Abstrak

Indeks Harga Konsumen (IHK) merupakan indikator penting dalam mengukur tingkat inflasi yang digunakan sebagai dasar pengambilan kebijakan ekonomi, termasuk penyesuaian gaji, upah, dan kontrak kerja. Karena IHK memiliki pengaruh penting terhadap perubahan laju inflasi perekonomian Indonesia, maka perlu dilakukan prediksi terhadap IHK untuk membantu pemerintah dalam merumuskan kebijakan yang tepat, baik dalam stabilisasi harga maupun perlindungan terhadap kesejahteraan masyarakat terutama di wilayah dengan aktivitas ekonomi tinggi seperti Kota Surabaya, yang memiliki pertumbuhan Produk Domestik Regional Bruto (PDRB) signifikan. Penelitian ini bertujuan untuk membandingkan kinerja dua fungsi aktivasi dalam model *Radial Basis Function Neural Network* (RBFNN), yaitu Gaussian dan Multikuadratik, dalam memprediksi laju IHK di Surabaya. Metode RBFNN dipilih karena kemampuannya dalam menangkap pola non-linear pada data deret waktu. Metodologi penelitian meliputi pengumpulan data dari Badan Pusat Statistik (BPS), pra-pemrosesan data, pengembangan model, dan evaluasi menggunakan data uji. Model RBFNN dibangun dengan menentukan kluster, nilai spread, fungsi aktivasi, dan output, serta dievaluasi menggunakan *Symmetric Mean Absolute Percentage Error* (sMAPE). Data yang digunakan berupa deret waktu Indeks Harga Konsumen (IHK) Kota Surabaya periode Januari 2006 hingga Desember 2024 dengan frekuensi bulanan, sehingga diperoleh 228 data observasi. Berdasarkan hasil analisis, diperoleh bahwa fungsi aktivasi Gaussian memberikan hasil prediksi terbaik dengan nilai SMAPE sebesar 0.70%, yang menunjukkan tingkat akurasi sangat tinggi. Hasil prediksi IHK untuk bulan Januari hingga Mei 2025 berturut-turut adalah 107.61, 108.09, 108.54, 108.95, dan 108.32.

Kata kunci: IHK, prediksi, RBFNN

Abstract

The Consumer Price Index (CPI) is an important indicator in measuring the inflation rate used as a basis for economic policy making, including adjustments to salaries, wages, and employment contracts. Because the CPI has a significant influence on changes in the inflation rate of the Indonesian economy, it is necessary to predict the CPI to assist the government in formulating appropriate policies, both in price stabilization and protecting public welfare, especially in areas with high economic activity such as Surabaya City, which has significant Gross Regional Domestic Product (GRDP) growth. This study aims to compare the performance of two activation functions in the Radial Basis Function Neural Network (RBFNN) model, namely Gaussian and Multiquadratic, in predicting the CPI rate in Surabaya. The RBFNN method was chosen because of its ability to capture non-linear patterns in time series data. The research methodology includes data collection from the Central Bureau of Statistics (BPS), data pre-processing, model development, and evaluation using test data. The RBFNN model was built by determining clusters, spread values, activation functions, and outputs, and was evaluated using Symmetric Mean Absolute Percentage Error (sMAPE). The data used is a time series of the Consumer Price Index (CPI) for Surabaya City from January 2006 to December 2024 with a monthly frequency, resulting in 228 observations. The analysis revealed that the Gaussian activation function provided the best prediction results with an SMAPE value of 0.70%, indicating a very high level of accuracy. The CPI predictions for January to May 2025 were 107.61, 108.09, 108.54, 108.95, and 108.32, respectively.

Keywords: CPI, prediction, RBFNN

This work is an open access article and licensed under a Creative Commons Attribution-NonCommercial ShareAlike 4.0 International (CC BY-NC-SA 4.0)



1. PENDAHULUAN

Indeks Harga Konsumen (IHK) adalah salah satu tolak ukur ekonomi untuk mengukur tingkat inflasi dalam suatu wilayah dengan memantau pergerakan harga dari sejumlah barang dan jasa yang dikonsumsi oleh rumah tangga[1]. Di Indonesia, Badan Pusat Statistik (BPS) membagi IHK menjadi sebelas kelompok pengeluaran utama, seperti perumahan, air, listrik, gas dan bahan bakar, bahan makanan, makanan jadi, minuman, rokok dan tembakau, sandang, serta kelompok lainnya. Fluktuasi nilai IHK dari waktu ke waktu menandakan tingkat tingkat penurunan (deflasi) atau kenaikan (inflasi) pada harga barang dan jasa di tingkat konsumen. IHK juga digunakan sebagai pertimbangan untuk penyesuaian gaji, upah, uang pensiun dan kontrak lainnya[2].

Mengingat pengaruh IHK terhadap perubahan laju inflasi perekonomian Indonesia, maka perlu dilakukan prediksi terhadap IHK. Karena IHK yang tidak stabil akan mempengaruhi laju inflasi, dan laju inflasi yang tidak stabil dapat mengganggu stabilitas ekonomi, menurunkan daya beli masyarakat, serta menimbulkan ketidakpastian dalam keputusan investasi dan konsumsi[3]. Forecasting merupakan perkiraan terhadap sesuatu yang belum terjadi[4]. Salah satu pendekatan yang dapat digunakan untuk memprediksi kejadian di masa mendatang berdasarkan data atau periode sebelumnya adalah analisis deret waktu, yaitu metode peramalan yang berfokus pada data historis untuk mendapatkan model terbaik dengan membandingkan antara data aktual dan data prediksi[5]-[6].

Kegiatan ekonomi di suatu negara merupakan salah satu kegiatan penting yang digunakan untuk menentukan pertumbuhan ekonomi[7]. Menurut data Badan Pusat Statistik (BPS), Kota Surabaya menempati posisi ketiga dengan nilai Produk Domestik Regional Bruto (PDRB) tertinggi di Indonesia. Pada Triwulan III 2024, laju pertumbuhan ekonomi Surabaya mencapai 5,45% (y-on-y), melampaui pertumbuhan Jawa Timur (4,91%) dan nasional (4,95%). Semakin besar PDRB maka semakin tinggi laju pertumbuhan ekonomi. Karena laju pertumbuhan ekonomi yang lebih tinggi, maka diperlukan prediksi IHK di Kota Surabaya untuk menjaga stabilitas daya beli masyarakat dan mengantisipasi adanya inflasi[8].

Pada prediksi diperlukan suatu metode yang dapat menangkap pola deret waktu, yang terdiri dari tren, musim, dan *noise*[9]. salah satunya adalah Jaringan Saraf Tiruan (JST) yang efektif dalam memodelkan hubungan non-linear antara input dan output. Salah satu tipe JST yang sering digunakan untuk peramalan adalah Radial Basis Function Neural Network (RBFNN). Arsitektur RBFNN terdiri dari lapisan input, lapisan tersembunyi serta lapisan output. Dalam RBFNN, fungsi aktivasi berperan menentukan respons neuron terhadap jarak antara input dan pusatnya. Umumnya digunakan fungsi Gaussian yang menurun secara eksponensial seiring bertambahnya jarak dari pusat. Sementara itu, fungsi Multikuadratik memiliki karakteristik sebaliknya, yaitu meningkat ketika jarak semakin jauh dari pusat neuron[10].

Berdasarkan penelitian sebelumnya yang dilakukan oleh[11], mengenai peramalan kunjungan wisatawan dengan menggunakan Radial Basis Function Neural Network. Data yang digunakan merupakan data historis jumlah kunjungan wisatawan mancanegara ke Indonesia dari 2008 hingga tahun 2020. Berdasarkan penelitian tersebut didapatkan bahwa terdapat model terbaik dengan 2 neuron pada lapisan input, 8 neuron pada lapisan tersembunyi, dengan nilai spread 1 didapatkan MSE untuk data latih sebesar 0,0088 dan nilai MAPE pengujian sebesar 5,2559%. Kecepatan konvergensi pelatihan selama 1 menit 16 detik dengan akurasi jaringan sebesar 94,7441%.

Berdasarkan penelitian sebelumnya yang dilakukan oleh[12]. Mengenai perbandingan Adaptive Neuro Fuzzy (ANFIS) dan Radial Basis Function Neural Network (RBFNN) untuk memprediksi kecepatan angin dengan menggunakan 54 data uji, nilai RMSE untuk metode RBFNN adalah 0.1766 sedangkan RMSE metode ANFIS adalah 1.1456. sehingga menunjukkan bahwa metode RBFNN unggul daripada metode ANFIS untuk melakukan prediksi kecepatan angin di Pulau Bintan. Sehingga dapat disimpulkan bahwa metode RBFNN lebih unggul dalam melakukan prediksi kecepatan angin di Pulau Bintan.


Pada penelitian yang dilakukan oleh[13]. Metode Radial Basis Function Neural Network (RBFNN) digunakan untuk peramalan Indeks Harga Saham Gabungan (IHSG) dengan fungsi aktivasi Gaussian. Berdasarkan penelitian tersebut didapatkan nilai MAPE untuk data training sebesar 0,72% dan nilai MAPE untuk data testing sebesar 0,70%. Hal ini membuktikan efektivitas fungsi Gaussian dalam menangkap hubungan non-linear pada data keuangan yang fluktuatif. Namun, karena karakteristik respon Gaussian menurun terhadap jarak dari pusat neuron, pengaruh tiap neuron menjadi terbatas. Oleh

sebab itu, penelitian ini membandingkan fungsi aktivasi Gaussian dan Multikuadratik untuk mengetahui fungsi yang lebih sesuai dalam memprediksi Indeks Harga Konsumen (IHK) di Kota Surabaya.

Penelitian ini bertujuan untuk membandingkan kinerja dua fungsi aktivasi yang umum digunakan dalam RBFNN, yaitu Gaussian dan Multiquadratik, dalam memprediksi laju IHK di Surabaya. Dengan menguji kedua fungsi aktivasi tersebut, penelitian ini diharapkan dapat mengidentifikasi fungsi mana yang mampu menghasilkan tingkat akurasi terbaik dalam memberikan prediksi IHK. Inovasi dari penelitian ini adalah membandingkan kinerja dua jenis fungsi aktivasi. Temuan penelitian ini diharapkan menjadi pertimbangan bagi pemerintah dalam membuat kebijakan pengendalian inflasi, perlindungan daya beli masyarakat, serta perencanaan ekonomi jangka menengah dan panjang.

2. METODE PENELITIAN

Pada Gambar 1, penelitian dimulai dengan proses input data IHK. Selanjutnya, data tersebut dilakukan preprocessing, yang mencakup mengubah data ke dalam format time series, mengecek missing value, melakukan uji PACF untuk menentukan data input pada input layer, serta menormalisasi data. Tahap berikutnya adalah pembagian dataset menjadi data training dan data testing. Proses kemudian dilanjutkan dengan pemodelan menggunakan Radial Basis Function Neural Network (RBFNN), yang meliputi penghitungan jarak Euclidean dengan algoritma K-Means, penghitungan nilai spread, penghitungan nilai aktivasi Gaussian dan Multikuadratik, serta penghitungan bobot output. Setelah pemodelan selesai, dilakukan evaluasi model dan prediksi untuk menguji performa model.



Gambar 1 Flowchart Metode Penelitian

1. Sumber data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari laman resmi Badan Pusat Statistik (BPS) Surabaya dan juga berita resmi statistik yang dikeluarkan setiap bulan oleh BPS terkait perkembangan IHK. Variabel yang digunakan dalam penelitian merupakan laju inflasi bulanan mulai Januari 2006 hingga Desember 2024 sebanyak 228 data.

2. Preprocessing data

Preprocessing adalah tahap pengolahan data mentah agar menjadi lebih bersih dan siap digunakan untuk analisis lebih lanjut[14]. Tahapan yang dilakukan dalam preprocessing data meliputi:

2.1 Pengecekan missing value

Missing value adalah kondisi hilangnya nilai pada suatu atribut data yang dapat disebabkan oleh beberapa faktor, seperti ketidakakuratan saat pengumpulan data, atau ketidakmampuan partisipan dalam memberikan jawaban yang valid. Oleh karena itu, pengecekan missing value merupakan langkah penting dalam preprocessing data untuk memastikan tidak ada data yang hilang. Jika terdapat missing value, maka dapat dilakukan pengisian nilai yang hilang dengan menggunakan metode imputasi seperti mean, median dan modus[15].

2.2 Mengubah format data

Pada tahap ini, data yang awalnya dalam format mentah diubah menjadi format time series agar dapat dianalisis secara temporal. Pengubahan ke format time series ini memungkinkan data untuk diolah berdasarkan urutan waktu

2.3 Uji *Partial Autocorrelation Function* (PACF)

Partial Autocorrelation Function (PACF) digunakan untuk mengidentifikasi hubungan antara suatu observasi dan observasi sebelumnya dalam data, dengan mengabaikan pengaruh dari observasi pada jarak waktu yang lebih jauh[16].

2.4 Normalisasi data

Normalisasi merupakan suatu teknik transformasi pada data untuk menyelaraskan rentang nilai pada data ke dalam skala tertentu[17].

$$X' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Keterangan

X' : nilai data normalisasi
 x : data yang akan diproses normalisasi
 x_{min} : nilai minimum dari seluruh data
 x_{max} : nilai maksimum dari seluruh data

3. Pembagian dataset

Setelah menetapkan variabel input berdasarkan plot PACF, tahap berikutnya adalah membagi data menjadi 2, yaitu data *training* dan data *testing*. Dalam penelitian ini menguji tiga komposisi pembagian data dengan pembagian 70:30, 80:20, dan 90:10.

4. *Radial Basis Function Neural Network* (RBFNN)

Radial Basis Function Neural Network adalah bagian dari JST dengan model yang bersifat *feedforward*. RBFNN merupakan metode JST yang memiliki fungsi aktivasi radial basis yang artinya sifatnya pada jarak dari titik pusat tertentu dalam ruang input. seringkali digunakan dalam kasus prediksi, peramalan maupun klasifikasi. RBFNN memiliki karakteristik yang unik karena mengkombinasikan dua pendekatan, yaitu *supervised* dan *unsupervised*[18].

K-means clustering merupakan metode yang berfungsi untuk menemukan satu set pusat yang lebih akurat mencerminkan distribusi titik data. Jumlah centroid ditentukan di awal dan setiap centroid mewakili sekelompok titik data. Pada metode *K-means*, data dikelompokkan kedalam K cluster. Kemudian dilakukan proses iteratif untuk menghitung nilai rata-rata setiap cluster. Adapun tahapan proses *Radial Basis Function Neural Network* adalah Sebagai berikut:

1. Menghitung jarak euclidean menggunakan metode *K-means* menggunakan persamaan berikut

$$D_{ik} = \|x_{ij} - x_{kj}\| = \sqrt{\sum_{j=1}^p (x_{ij} - x_{kj})^2} \quad (2)$$

Keterangan:

D_{ik} : Jarak *euclidean* antara titik i dan titik k

x_{ij} : Koordinat titik i pada kolom ke-j

x_{kj} : Koordinat titik k pada kolom ke-j

p : Jumlah dimensi pada data atau jumlah kolom

2. Menghitung spread berdasarkan persamaan berikut

$$\sigma_j = \frac{d_{max}}{\sqrt{2K}} \quad (3)$$

Keterangan:

σ_j : nilai spread ke-j

d_{max} : jarak maksimal antar pusat *cluster*

K : banyaknya cluster yang terbentuk

3. Menghitung fungsi aktivasi gaussian dan multikuadratik berdasarkan persamaan (4) dan (5)

$$\Phi = e^{(-x^2/2\sigma^2)} \quad (4)$$

Keterangan

Φ : Fungsi aktivasi gaussian

x : jarak euclidean

σ : *spread* dari fungsi radial basis

$$\Phi = \sqrt{x^2 + \sigma^2} \quad (5)$$

Keterangan

Φ : Fungsi aktivasi multikuadratik

x : jarak euclidean

σ : *spread* dari fungsi radial basis

4. Menentukan nilai bobot lapisan dan bobot bias lapisan w_t dan b_1 yang dapat diselesaikan dengan metode Least Square

$$\begin{aligned} \varphi_{11}w_1 + \varphi_{12}w_1 + \dots + \varphi_{1n}w_n + b_2 &= d_1 \\ \varphi_{21}w_1 + \varphi_{22}w_1 + \dots + \varphi_{2n}w_n + b_2 &= d_2 \\ &\dots \\ \varphi_{n1}w_1 + \varphi_{n2}w_2 + \dots + \varphi_{nn}w_1 + b_2 &= d_n \end{aligned} \quad (6)$$

Persamaan diatas dapat disusun menjadi bentuk matrik sebagai berikut

$$\begin{bmatrix} \varphi_{11} & \varphi_{12} & \dots & \varphi_{1n} & 1 \\ \varphi_{21} & \varphi_{22} & \dots & \varphi_{2n} & 1 \\ \vdots & \vdots & & \vdots & \vdots \\ \varphi_{n1} & \varphi_{n2} & \dots & \varphi_{11} & 1 \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \\ b_2 \end{bmatrix} = \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_n \end{bmatrix}$$

Atau dapat dinotasikan sebagai berikut

$$G w = d$$

$$d = [d_1 \quad d_2 \quad \dots \quad d_n]^T$$

$$w = [w_1 \quad w_2 \quad \dots \quad w_n]^T$$

$$G = \varphi_{nn}$$

Sehingga

$$w = (G^T G)^{-1} G^T d \quad (7)$$

Keterangan

G : matriks fitur

w : vektor bobot

d : vektor output yang ingin diprediksi

5. Evaluasi model

Proses terakhir yaitu mengevaluasi model menggunakan metode Symmetric Mean Absolute Percentage Error (SMAPE) adalah pembaruan dari metode MAPE yang digunakan untuk mengevaluasi ketepatan prediksi. Penggunaan SMAPE dapat mengatasi masalah pembesaran error saat data aktual mendekati nol serta perbedaan signifikan dalam nilai absolut error ketika data aktual lebih besar atau lebih kecil dari hasil prediksi. nilai SMAPE yang rendah menunjukkan tingkat kesalahan prediksi yang lebih kecil pada metode prediksi yang diterapkan[19].

$$SMAPE = \frac{2}{n} \sum_{t=1}^n \frac{|y_t - x_t|}{(|x_t| + |y_t|)} \times 100\% \quad (8)$$

Keterangan

x_t : data aktual periode ke-t

y_t : hasil prediksi periode ke-t

n : jumlah total data

Tabel 1 Tabel rentang nilai SMAPE

SMAPE	Kategori
$\leq 10\%$	Sangat baik
10% - 20%	Baik
20% -50%	Layak
$\geq 50\%$	Buruk

3. HASIL DAN PEMBAHASAN

3.1 Transformasi data time series

Berikut merupakan hasil transformasi data kedalamformat time series

Tabel 2 Tabel data dalam format time series

Tanggal	IHK
2006-01-01	135.47
2006-02-01	135.98
2006-03-01	136.19
2006-04-01	136.76
2006-05-01	136.92
....	
2024-08-01	106.44

Tanggal	IHK
2024-09-01	106.32
2024-10-01	106.44
2024-11-01	106.64
2024-12-01	107.11


3.2 Pembagian Data

Jumlah pembagian data terdapat pada tabel 4 dibawah ini

Tabel 3 Pembagian Data

Presentase	Data <i>Training</i>	Data <i>Testing</i>
90%:10%	205	23
80%:20%	182	46
70%:30%	160	68

3.3 Menentukan Input Jaringan



Gambar 2 Plot PACF

Berdasarkan plot Partial Autocorrelation Function (PACF) pada Gambar 2, terlihat bahwa lag ke-1 berada di luar batas interval kepercayaan, yang menunjukkan signifikansi. Hal ini mengindikasikan bahwa lag 1 memiliki pengaruh parsial yang kuat terhadap nilai IHK saat ini, sementara lag lainnya tidak signifikan. Oleh karena itu, lag 1 dipilih sebagai input pada model RBFNN. Nilai data input yang digunakan ditampilkan pada Tabel 4

Tabel 4 Data input

Tanggal	x_t	x_{t-1}
2006-02-01	0.571	0.561
2006-03-01	0.574	0.571
2006-04-01	0.584	0.574
2006-05-01	0.587	0.584
2006-06-01	0.598	0.587
⋮	⋮	⋮
2020-10-01	0.001	0.002
2020-11-01	0.005	0.001
2020-12-01	0.014	0.005
2021-01-01	0.021	0.014
2021-02-01	0.027	0.021

3.4 Menentukan jumlah *cluster*

Penentuan jumlah *cluster* yang optimal dilakukan dengan menguji beberapa nilai K (jumlah cluster) yaitu 2, 3, 4, dan 5. Setiap nilai K digunakan dalam proses pelatihan model untuk mengamati pengaruhnya terhadap akurasi prediksi.

3.5 Menentukan nilai *Spread*

Perhitungan nilai spread berdasarkan jumlah cluster terbaik

$$\sigma_5 = \frac{0.7686}{\sqrt{2 \cdot 5}} = 0.2431$$

3.6 Menghitung fungsi aktivasi gaussian dan multikuadratik

Untuk input data pertama, perhitungan fungsi aktivasi gaussian dan multikuadratik adalah sebagai berikut.

Fungsi aktivasi gaussian:

$$\Phi = e^{((-0.1780)^2/2 \cdot (0.2431)^2)} = 0.7647$$

Fungsi aktivasi multikuadratik:

$$\Phi = \sqrt{0.1780^2 + 0.2431^2} = 0.3012$$

3.7 Menghitung bobot

Berikut merupakan matriks fitur, vektor bobot dan vektor output dengan fungsi aktivasi gaussian

$$\begin{bmatrix} 0.301 & 0.601 & 0.327 & 0.455 & 0.243 & 1 \\ 0.306 & 0.609 & 0.321 & 0.463 & 0.243 & 1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0.441 & 0.243 & 0.803 & 0.291 & 0.600 & 1 \\ 0.436 & 0.243 & 0.796 & 0.288 & 0.594 & 1 \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_5 \\ b_2 \end{bmatrix} = \begin{bmatrix} 0.561 \\ 0.571 \\ \vdots \\ 0.014 \\ 0.021 \end{bmatrix}$$

Dengan menggunakan metode least square maka diperoleh bobot lapisan yaitu (-3.627, -2.501, -4.173, 3.197, 4.485) dan bobot bias lapisan adalah 1.960

3.8 Menghitung Output

Setelah dilakukan penghitungan bobot, bobot tersebut akan dikalikan dengan vektor matriks fitur pada data testing untuk mengetahui nilai output prediksi. Berikut merupakan proses perhitungannya

$$\begin{bmatrix} 0.431 & 0.243 & 0.791 & 0.285 & 0.589 & 1 \\ 0.430 & 0.243 & 0.790 & 0.284 & 0.587 & 1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0.417 & 0.245 & 0.775 & 0.276 & 0.573 & 1 \\ 0.414 & 0.245 & 0.771 & 0.274 & 0.569 & 1 \end{bmatrix} \begin{bmatrix} -3.627 \\ -2.501 \\ -4.173 \\ 3.197 \\ 4.485 \\ 1.960 \end{bmatrix} = \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_{44} \\ d_{45} \end{bmatrix}$$

Berdasarkan pelatihan tersebut didapatkan output prediksi untuk 5 data testing pertama merupakan 0.036, 0.037, 0.039, 0.046, 0.042 lalu setelah dilakukan denormalisasi maka hasilnya 105.95, 106.04, 106.15, 106.51, 106.32

3.9 Evaluasi model


Berikut merupakan evaluasi model untuk data testing dengan pembagian 90:10, 80:20, dan 70:30. Tabel disajikan untuk masing-masing proporsi data split serta jenis fungsi aktivasi berdasarkan SMAPE terkecil.

Tabel 5 Hasil evaluasi model

Data Split	Fungsi Aktivasi	Jumlah Cluster	SMAPE <i>Training</i>	SMAPE <i>Testing</i>
90:10	Gaussian	4	1.18%	0.94%
90:10	Multikuadratik	5	1.18%	0.84%
80:20	Gaussian	5	1.38%	0.70%
80:20	Multikuadratik	5	1.18%	0.56%
70:30	Gaussian	4	1.29%	2.75%
70:30	Multikuadratik	3	0.99%	1.02%

Pada Tabel 5 terlihat bahwa untuk semua jenis pembagian data, fungsi aktivasi multikuadratik memiliki nilai SMAPE lebih baik daripada Gaussian. Proporsi data berpengaruh terhadap kinerja model karena menentukan seberapa banyak data yang digunakan pada proses training dan testing. Pada proporsi 80:20, model memperoleh keseimbangan yang optimal antara kemampuan belajar dari data dan kemampuan generalisasi terhadap data baru. Sementara itu, jumlah kluster memengaruhi kemampuan model dalam mengenali pola, jumlah kluster yang terlalu sedikit dapat menyederhanakan struktur data, sedangkan terlalu banyak dapat menimbulkan overfitting.

Berdasarkan keseluruhan hasil, kombinasi fungsi aktivasi Multikuadratik dan jumlah kluster 5 pada data split 80:20 memberikan performa terbaik, ditunjukkan oleh nilai sMAPE testing terendah sebesar 0,56%. Berdasarkan temuan ini, untuk implementasi pada kasus serupa disarankan menggunakan fungsi aktivasi Multikuadratik, karena mampu menangkap pola data IHK di Surabaya yang memiliki kecenderungan tren jangka panjang. Fungsi ini juga lebih sesuai untuk memodelkan pergerakan data ekonomi yang bersifat halus namun konsisten, dibandingkan dengan fungsi Gaussian yang cenderung lebih sensitif terhadap perubahan lokal di sekitar pusat neuron.




Gambar 3 Perbandingan data aktual dan hasil prediksi

Gambar 3 menunjukkan perbandingan antara data aktual dengan hasil prediksi menggunakan fungsi aktivasi Gaussian dan Multikuadratik pada model RBFNN. Data yang digunakan merupakan data bulanan Indeks Harga Konsumen (IHK). Berdasarkan eksperimen dengan nilai SMAPE terbaik, yaitu pada pembagian data 80:20, terlihat bahwa garis hijau yang merepresentasikan hasil prediksi dengan fungsi aktivasi Multikuadratik lebih mendekati garis hitam sebagai representasi data aktual dibandingkan dengan garis biru

yang merupakan hasil prediksi menggunakan fungsi aktivasi Gaussian. Hal ini mengindikasikan bahwa fungsi aktivasi Multikuadratik memberikan hasil prediksi yang lebih baik dalam menangkap pola perubahan IHK dibandingkan fungsi aktivasi Gaussian.

3.10 Prediksi Indeks Harga Konsumen



Gambar 4 Hasil prediksi 5 bulan kedepan

Prediksi data menggunakan RBFNN akan digunakan untuk memprediksi nilai IHK untuk 5 bulan kedepan yaitu Januari hingga Mei 2025 yang divisualisasikan pada gambar 4. Garis biru merepresentasikan tren bulanan IHK dari tahun 2006 hingga 2024. Sementara itu, garis merah mewakili hasil prediksi IHK untuk lima bulan ke depan. Hasil prediksi menunjukkan kecenderungan menaik setelah akhir tahun 2024.

Tabel 6 Hasil Prediksi 5 bulan kedepan

Tanggal	IHK
2025-01-01	107.61
2025-02-01	108.09
2025-03-01	108.54
2025-04-01	108.95
2025-05-01	108.32

Berdasarkan hasil prediksi yang ditampilkan pada Tabel 6, nilai Indeks Harga Konsumen (IHK) di Kota Surabaya selama lima bulan ke depan, mulai Januari hingga Mei 2025, menunjukkan tren peningkatan secara bertahap

4. KESIMPULAN

Berdasarkan hasil prediksi Indeks Harga Konsumen menggunakan metode *Radial Basis function Neural Network*, didapatkan bahwa model memberikan performa terbaik ketika menggunakan fungsi aktivasi multikuadratik dengan jumlah *cluster* 5 dan pembagian data 80:20. memiliki nilai SMAPE sebesar 0.56%. Berdasarkan model terbaik yang diperoleh, dilakukan prediksi untuk lima bulan ke depan setelah data terakhir yaitu untuk Januari hingga Mei 2025. Hasil prediksi tersebut secara bertahap, yaitu sebesar 107.61, 108.09, 108.54, 108.95, dan 108.32. Hasil prediksi menunjukkan adanya tren kenaikan IHK dari 107,61 hingga 108,95. Tren ini sejalan dengan pola historis inflasi yang cenderung meningkat pada periode tertentu. Kenaikan bertahap tersebut mengindikasikan adanya inflasi yang masih terkendali, namun potensi peningkatan harga barang dan jasa tetap perlu diantisipasi agar tidak

menurunkan daya beli masyarakat maupun memperlambat pertumbuhan ekonomi. Saran untuk penelitian selanjutnya adalah agar pemilihan jumlah *cluster* tidak berdasarkan hasil pengujian terbatas melainkan menggunakan pendekatan seperti *silhouette score* untuk mendapatkan jumlah *cluster* yang optimal.

DAFTAR PUSTAKA

- [1] Silvia Diva Sari, Joy Stevani Simangunsong, and Novita Sari Siboro, "Pengaruh Indeks Harga Konsumen terhadap Inflasi di Kota Medan Sumatera Utara Tahun 2024," *Jurnal Penelitian Ekonomi Manajemen dan Bisnis*, vol. 4, no. 2, pp. 53–61, Apr. 2025, doi: 10.55606/jekombis.v4i2.5009.
- [2] Y. A. Lesnussa, H. W. M. Patty, A. N. Mahu, and M. Y. Matdoan, "ANALISIS INDEKS HARGA KONSUMEN TERHADAP INDEKS HARGA SANDANG DAN PANGAN DI KOTA AMBON," 2018. doi: 10.33603/e.v5i1.839.
- [3] M. S. Desfitra, Z. Aulia, R. P. Utami, and N. Fitriana, "Pengaruh Inflasi Terhadap Pertumbuhan Ekonomi Di Indonesia," 2024. doi: 10.62379/jebd.v2i4.
- [4] M. Idhom and S. M. Huda, "SISTEM INFORMASI PERAMALAN PENJUALAN DENGAN METODE LEAST SQUARE STUDI KASUS : CV. AGP COMPUTER," vol. XII, no. 1, pp. 25–34, Jan. 2017, doi: 10.33005/scan.v12i1.879.
- [5] M. Idhom, A. Fauzi, T. Trimono, and P. Riyantoko, "Time Series Regression: Prediction of Electricity Consumption Based on Number of Consumers at National Electricity Supply Company," *TEM Journal*, vol. 12, no. 3, pp. 1575–1581, Aug. 2023, doi: 10.18421/TEM123-39.
- [6] P. A. Riyantoko, T. M. Fahrudin, K. M. Hindrayani, A. Muhaimin, and Trimono, "Water Availability Forecasting Using Univariate and Multivariate Prophet Time Series Model for ACEA (European Automobile Manufacturers Association)," *Internasional Journal of Data Science, Engineering, and Analytics*, vol. 1, no. 2, pp. 43–54, Nov. 2021, doi: 10.33005/ijdasea.v1i2.12.
- [7] T. Trimono and D. A. Maruddani, "COMPARISON BETWEEN VALUE AT RISK AND ADJUSTED EXPECTED SHORTFALL: A NUMERICAL ANALYSIS," *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, vol. 17, no. 3, pp. 1347–1358, Sep. 2023, doi: 10.30598/barekengvol17iss3pp1347-1358.
- [8] P. Romhadhoni, D. Z. Faizah, and N. Afifah, "Pengaruh Produk Domestik Regional Bruto (PDRB) Daerah Terhadap Pertumbuhan Ekonomi dan Tingkat Pengangguran Terbuka di Provinsi DKI Jakarta," vol. 14, no. 2, pp. 115–121, 2018, doi: 10.24198/jmi.v14.n2.2018.115-121.
- [9] A. T. Damaliana, K. M. Hindrayani, and T. M. Fahrudin, "Hybrid Holt Winter-Prophet method to forecast the number of foreign tourist arrivals through Bali's Ngurah Rai Airport," vol. 3, no. 2, pp. 21–32, 2023, doi: 10.3390/xxxxx.
- [10] A. Kumar Yadu and G. Shrivastava, "Study of Applications of Radial Basis Function Network in Forecasting," 2021. [Online]. Available: <http://chrisjmcormick.files.wordpress.com/2013/08/>.
- [11] M. Dwi Cahyo and S. Heranurweni, "PREDIKSI BEBAN ENERGI LISTRIK APJ KOTA SEMARANG MENGGUNAKAN METODE RADIAL BASIS FUNCTION (RBF)," 2019. doi: 10.26623/elektrika.v11i2.1699.
- [12] N. Nikentari, M. Bettiza, H. Sasty, and P. #3, "Prediksi Kecepatan Angin Menggunakan Adaptive Neuro Fuzzy (ANFIS) dan Radial Basis Function Neural Network (RBFNN)," *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, vol. 4, no. 1, pp. 70–75, 2018, doi: 10.26418.
- [13] A. R. Brendita et al., "PERAMALAN INDEKS HARGA SAHAM GABUNGAN (IHSG) DENGAN METODE RADIAL BASIS FUNCTION NEURAL NETWORK MENGGUNAKAN GUI MATLAB," vol. 7, no. 4, pp. 431–442, 2018, [Online]. Available: <https://ejournal3.undip.ac.id/index.php/gaussian/>
- [14] A. Nurkholis, D. Alita, and A. Munandar, "Comparison of Kernel Support Vector Machine Multi-Class in PPKM Sentiment Analysis on Twitter," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 2, pp. 227–233, Apr. 2022, doi: 10.29207/resti.v6i2.3906.

- [15] A. Seto Arifianto, K. Dewi Safitri, K. Agustianto, G. Wiryawan, and P. N. Jember, "PENGARUH PREDIKSI MISSING VALUE PADA KLASIFIKASI DECISION TREE C4.5," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, vol. 9, pp. 779–786, 2022, doi: 10.25126/jtiik.202294778.
- [16] M. Heru Widiyanto and R. Mayasari, "IMPLEMENTASI TIME SERIES PADA DATA PENJUALAN DI GAIKINDO MENGGUNAKAN ALGORITMA SEASONAL ARIMA," 2023. doi: 10.36040/jati.v7i3.
- [17] D. Azzahra Nasution, H. H. Khotimah, and N. Chamidah, "PERBANDINGAN NORMALISASI DATA UNTUK KLASIFIKASI WINE MENGGUNAKAN ALGORITMA K-NN," 2019. doi: 10.24114/cess.v4i1.
- [18] V. Wahyuningrum, B. Pusat, S. Provinsi, and J. Barat, "PENERAPAN RADIAL BASIS FUNCTION NEURAL NETWORK DALAM PENGKLASIFIKASIAN DAERAH TERTINGGAL DI INDONESIA," 2020. doi: 10.34123.
- [19] D. C. I. Astuti, D. M. Khairina, and S. Maharani, "Peramalan Nilai Ekspor Nonmigas Kalimantan Timur dengan Metode Double Moving Average (DMA)," *Adopsi Teknologi dan Sistem Informasi (ATASI)*, vol. 2, no. 1, pp. 20–34, Jun. 2023, doi: 10.30872/atasi.v2i1.393.