



Peramalan Inflasi di Provinsi Gorontalo Menggunakan Metode General Regression Neural Network (GRNN)

Isran K. Hasan^{1*}, Novianita Achmad², Putri Lapitung¹

¹) Program Studi Statistika, Universitas Negeri Gorontalo, Bone Bolango 96554, Indonesia

²) Program Studi Matematika, Universitas Negeri Gorontalo, Bone Bolango 96554, Indonesia

Info Artikel

*Penulis Korespondensi.
Email: isran.hasan@ung.ac.id

Submit: 13 Desember 2023
Direvisi: 27 Januari 2024
Disetujui: 31 Januari 2024



Under the licence
CC BY-NC-SA 4.0

Diterbitkan oleh:



Copyright ©2024 by Author(s)

Abstrak

Peramalan tingkat inflasi memiliki kepentingan signifikan karena hasilnya berfungsi sebagai indikator yang dapat mempengaruhi pembuatan kebijakan di masa mendatang. Salah satu kebijakan yang dipengaruhi oleh hasil peramalan ini adalah kebijakan ekonomi dan kebijakan moneter. Dalam penelitian ini metode yang digunakan adalah general regression neural network (GRNN). Peramalan ini diterapkan pada data inflasi di Provinsi Gorontalo pada bulan Januari 2008 sampai April 2023, dengan kesimpulan menghasilkan peramalan inflasi pada bulan Mei – Desember 2023 dengan nilai MAPE sebesar 3,24% atau tingkat akurasi 96,76%.

Kata Kunci: Peramalan; Inflasi; JST; Neural Network; MAPE

Abstract

Forecasting the inflation rate is important because the results obtained are used as an indicator that can influence the policies that will be made later. One policy that uses the results of this forecasting as one of the things that can influence it is economic policy and monetary policy. In this study the method used is the general regression neural network (GRNN). This forecast is applied to inflation data in Gorontalo Province from January 2008 to April 2023, with the conclusion that it produces an inflation forecast for May – December 2023 with a MAPE value of 3.24% or an accuracy rate of 96.76%.

Keywords: Forecasting; Inflation; JST; Neural Network; MAPE

1. Pendahuluan

Statistika dapat diuraikan sebagai strategi untuk mengumpulkan, membuat, menyajikan, memeriksa, dan menguraikan informasi sebagai angka [1]. Statistika banyak digunakan dalam bidang ekonomi salah satunya untuk meramalkan perkembangan ekonomi di masa depan. Di era globalisasi, ketidakpastian terhadap data perekonomian di Indonesia selalu terjadi, misalnya inflasi. Inflasi adalah meningkatnya harga secara keseluruhan dan terjadi tanpa henti. Kenaikan harga satu dari beberapa produk tidak dapat dikatakan inflasi, kecuali jika kenaikannya jauh dan luas dan menyebabkan perluasan di sebagian besar dari hal yang berbeda. Kebalikan dari inflasi adalah deflasi yaitu penurunan harga barang secara keseluruhan dan terus menerus. Kestabilan dan rendahnya tingkat inflasi merupakan masalah yang pertama dan terpenting dalam kebijakan moneter karena kesulitan mengambil kebijakan untuk mengendalikan tingkat inflasi. Inflasi bukan hanya terjadi di suatu negara, tetapi dapat terjadi dalam wilayah provinsi dan kabupaten atau kota. Berdasarkan data inflasi Provinsi Gorontalo periode Agustus 2008- April 2023, inflasi di Gorontalo cenderung fluktuatif hal ini disebabkan kondisi ekonomi serta faktor pandemi yang terjadi pada periode 2019-2022 [2].

Tingkat inflasi yang terjadi sekarang (current) dan dimasa depan (expected) akan berdampak signifikan dalam penetapan badan ekonomi untuk tabungan, investasi, produksi dan konsumsi. Peramalan tingkat inflasi menjadi krusial karena hasilnya berfungsi sebagai salah satu petunjuk yang dapat mempengaruhi pembuatan kebijakan di masa mendatang. Salah satu bidang kebijakan yang terdampak oleh hasil peramalan ini adalah kebijakan ekonomi dan kebijakan moneter. Dalam

permasalahan yang telah dijelaskan peneliti bermaksud akan meramalkan tingkat inflasi dengan memanfaatkan kecerdasan buatan jaringan syaraf tiruan (JST). JST sering dijadikan bahan penelitian kecerdasan buatan, hal ini disebabkan kemampuan JST dalam meniru sistem karakteristik input. Prosedur JST mencoba meniru cara kerja otak biologis dengan bentuk neuron-nya (sel syaraf) [3].

Peramalan adalah suatu proses untuk memproyeksikan kebutuhan di masa depan, termasuk kebutuhan dalam hal jumlah, kualitas, waktu, dan lokasi, dengan tujuan memenuhi permintaan atas barang dan jasa [2]. Dalam beberapa tahun terakhir, teknik-teknik pengembangan model peramalan yang berbasis pada kecerdasan buatan telah menarik perhatian peneliti dan praktisi di bidang statistika dan ekonomi. Salah satu pendekatan yang terbukti efektif dalam peramalan inflasi adalah menggunakan Generalized Regression Neural Network (GRNN).

GRNN adalah salah satu jenis jaringan saraf buatan yang menggunakan pendekatan nonparametrik dalam peramalan. GRNN dapat mengatasi beberapa tantangan dalam peramalan inflasi, termasuk nonlinieritas, pola musiman, dan efek jangka panjang yang kompleks. Pendekatan ini memungkinkan model untuk mempelajari pola dan hubungan yang kompleks di antara berbagai variabel ekonomi yang dapat mempengaruhi inflasi.

Peramalan menggunakan metode General Regression Neural Network banyak digunakan pada berbagai kasus seperti data pada kasus data saham [4], kasus KURS [5], kasus minyak mentah [6] dan produksi tanaman padi [7]. Dengan membandingkan metode GRNN dengan metode lainnya seperti ARIMA, FFN, ARCH, GARCH, IGARCH, APARCH dengan kesimpulan metode GRNN lebih akurat karena menghasilkan ukuran ketepatan peramalan terkecil. Pada penelitian ini dalam meramalkan inflasi peneliti menggunakan metode General Regression Neural Network untuk meramalkan inflasi di Provinsi Gorontalo.

2. Metode Penelitian

2.1 Pengumpulan Data

Data yang digunakan pada penelitian ini merupakan data sekunder tingkat inflasi dalam bentuk time series dari bulan januari tahun 2008 sampai dengan april tahun 2023 yang diambil dari Badan Pusat Statistik Provinsi Gorontalo melalui website resmi (<https://gorontalo.bps.go.id>).

2.2 Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF)

Autokorelasi digunakan untuk mengidentifikasi koefisien korelasi dalam deret waktu periodik dan untuk menganalisis pola data, termasuk trend atau musiman. Fungsi autokorelasi mencakup semua nilai autokorelasi untuk berbagai lag k.

$$\hat{p}_k = \frac{\sum_{t=k+1}^n (X_t - \tilde{X})(X_{t-1} - \tilde{X})}{\sum_{t=1}^n (X_t - \tilde{X})^2}$$

dengan :

- \hat{p}_k = autokorelasi pada lag k
- \tilde{X} = rata-rata dari pengamatan
- X_t = pengamatan pada waktu ke-t

Partial Autocorrelation Function (PACF) atau autokorelasi parsial digunakan untuk mengukur korelasi antara dengan setelah X_t dengan X_{t-k} setelah $X_{t-1}, X_{t-2}, X_{t-3}$ dihilangkan. *Autokorelasi parsial* diformulasikan sebagai berikut [8]

$$\theta_{kk} = \frac{|p_k|}{|P_k|}$$

dengan :

- θ_{kk} = nilai PACF ke k
- p_k = nilai PACF pada lag k
- P_k = nilai persamaan PACF pada aturan *cramer*

2.3 Fungsi Aktivasi

JST menggunakan fungsi aktivasi untuk memperoleh suatu neuron. Beberapa fungsi aktivasi yang digunakan yaitu [8].

1. Fungsi *Threshold*(Batas Ambang)

fungsi *Threshold* merupakan fungsi *Threshold biner* dapat dirumuskan:

$$f(x) = 1 \text{ jika } \geq \alpha$$
$$f(x) = 0 \text{ jika } < \alpha$$

2. Fungsi Sigmoid

Fungsi ini banyak digunakan karena sangat mudah digunakan diferensiasi.

$$f(x) = \frac{1}{1 + e^{-x}}$$

3. Fungsi identitas

Digunakan ketika keluaran JST menghasilkan sembarangan bilangan riil (bukan hanya pada [0,1] atau [1, -1]) $Y = x$.

2.4 General Regression Neural Network (GRNN)

GRNN adalah jaringan radial basis biasanya digunakan untuk pendekatan fungsi. GRNN pada dasarnya adalah Berdasarkan regresi non-linier (kernel), perkiraan dan kinerja Output ditentukan oleh jumlah input. Dibawah ini adalah persamaan GRNN :

$$E|Y|X = \frac{\int_{-\infty}^{\infty} yf(x, y)dy}{\int_{-\infty}^{\infty} f(x, y)dy}$$

dimana y merupakan output yang di prediksi oleh GRNN, x merupakan vektor input (x_1, x_2, \dots, x_p), p merupakan variabel prediktor. $E|Y-X|$ adalah harga harapan dari output y, vektor input X dan $f(xy)$ merupakan fungsi densitas probabilitas bersama X dan y.

Terdapat empat proses lapisan GRNN : *input layer, pattern, summation* dan *output*. Jaringan GRNN menggunakan fungsi aktivasi *radial basis* sebagai fungsi aktivasinya, $\theta_i = e^{-n^2}$ dengan $= b \cdot D_i$. b adalah bobot bias lapisan input khusus pada GRNN bobot bias lapisan input ini bernilai 0,8326/*spread* untuk semua *neuron* dan jarak *Euclidian* yang ditentukan Digunakan untuk menemukan fungsi aktivasi setiap neuron di lapisan input ke lapisan tersembunyi.

$$d_i = \sqrt{\sum_{i=1}^p (x_i - V_{ij})^2} \quad (I = 1,2,3,\dots,) \text{ dan } (j = 1,2,3,\dots,p)$$

Jarak yang ditemukan akan dimanfaatkan untuk menentukan nilai fungsi aktivasi untuk setiap neuron dari lapisan input ke lapisan tersembunyi. Setelah fungsi aktivasi terbentuk, proses berlanjut ke lapisan selanjutnya, yaitu lapisan penjumlahan (*summation layer*). Di dalam lapisan ini, terdapat dua tahap pemrosesan dalam jaringan. Tahap pertama melibatkan penjumlahan aritmatika untuk fungsi aktivasi (Ss), sedangkan tahap kedua melibatkan penjumlahan bobot (Sw), di mana bobot pada lapisan ini setara dengan nilai vektor target.

Setelah melakukan penjumlahan nilai fungsi aktivasi dan bobot, langkah selanjutnya adalah menuju ke lapisan output. Di lapisan ini, output dihasilkan melalui pembagian antara total nilai bobot dan nilai penjumlahan fungsi aktivasi.

$$\hat{y}_t = \frac{S_s}{S_w}$$

2.5 Ukuran Ketepatan Peramalan

Peramalan mengandung beberapa ketidakpastian karena faktor-faktor kesalahan dalam merumuskan prakiraan deret waktu. Terjadi penyimpangan prediksi tidak terbatas pada kesalahan elemen alasan lain adalah bahwa model prediktif tidak dapat mengenali ini data juga berpengaruh signifikan terhadap penyimpangan prediksi. Oleh karena itu untuk mengetahui ketepatan suatu peramalan maka akan digunakan ukuran kesalahan atau error. Adapun ukuran ketepatan yang sering digunakan untuk memprediksi yaitu nilai MAPE (*Mean Absolute Percentage Error*). Persamaan MAPE yaitu :

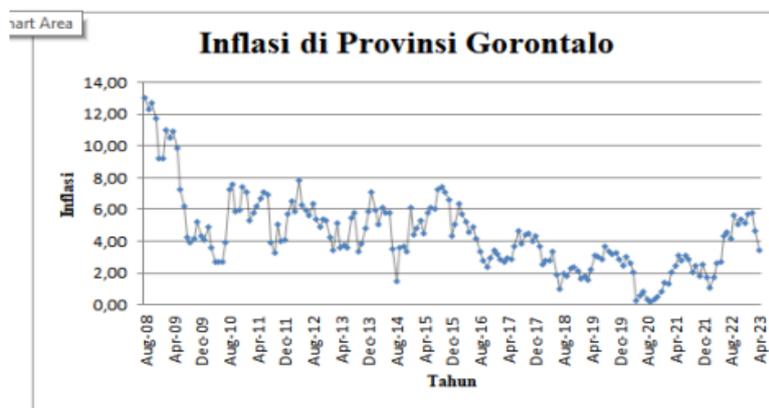
$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{Y_t} \times 100$$

Nilai MAPE dalam prediksi dikatakan sangat baik jika MAPE < 10 persen dan baik jika nilai MAPE < 20 persen. Untuk menentukan model peramalan yang paling baik dan memiliki tingkat akurasi yang lebih baik yaitu dilihat dari nilai MAPE yang paling kecil [9].

3. Hasil dan Pembahasan

3.1 Analisis Deskriptif

Jumlah data inflasi yang digunakan dalam penelitian sebanyak 177 data yang terdiri dari inflasi bulanan dari tahun 2009 hingga 2023 di provinsi provinsi Gorontalo yang didapat dari Badan Pusat Statistik Gorontalo. Berikut merupakan grafik inflasi bulanan dari bulan Agustus 2009 sampai April 2023.



Gambar 1. Grafik inflasi di Gorontalo periode Agustus 2008- April 2023

Berdasarkan gambar 1, inflasi di Gorontalo cenderung fluktuatif hal ini disebabkan kondisi ekonomi serta faktor pandemi yang terjadi pada periode 2019-2022. Inflasi tertinggi 13% yakni pada bulan Agustus 2008 dimana pada periode tersebut Pemerintah menaikkan harga BBM yang diakibatkan tingginya harga minyak dunia. Sedangkan inflasi terendah pada periode Agustus 2008 - April 2023 yakni 0,21% pada bulan September 2020 hal ini dipengaruhi oleh pandemi covid-19 yang sangat mempengaruhi kondisi sosial ekonomi masyarakat.

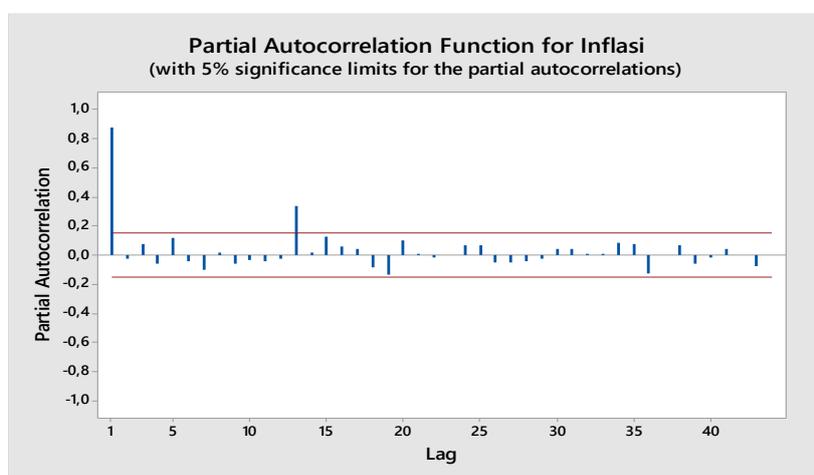
Tabel 1. Statistik Deskriptif

| N | Mean | Max | Min | Std. deviasi |
|-----|------|-------|------|--------------|
| 177 | 4.42 | 13.00 | 0.21 | 2.414439 |

Berdasarkan Tabel 1, diketahui rata-rata data inflasi gorontalo periode Agustus 2008 – April 2023 adalah 4.42, nilai maximum atau inflasi tertinggi yakni 13 dan nilai minimum atau inflasi terendah adalah 0.21 serta standar deviasi sebesar 2.414439.

3.2 Identifikasi Jaringan GRNN

Dalam konteks peramalan menggunakan Artificial Neural Network, model jaringan ini berfungsi untuk menentukan variabel input yang digunakan dalam meramalkan proses jaringan. Penentuan variabel input dapat dilakukan dengan memanfaatkan plot PACF. Dalam hal ini, penentuan variabel input didasarkan pada karakteristik model persamaan dalam peramalan, seperti persamaan model dalam proses Autoregresif (AR). Model AR mencerminkan pergerakan variabel melalui nilai-nilai masa lalu itu sendiri, atau dengan kata lain, menjelaskan sejauh mana nilai-nilai masa lalu mempengaruhi nilai saat ini.

**Gambar 2.** Plot PACF Inflasi

Berdasarkan gambar 2, plot PACF menunjukkan adanya puncak yang signifikan pada lag 1 dan lag 13. Hal ini menunjukkan bahwa ada korelasi yang signifikan pada lag-lag tersebut. Korelasi yang signifikan pada lag 1 dan lag 13 menandakan adanya hubungan autoregresif yang kuat dan memiliki pengaruh langsung pada nilai variabel target saat ini. Secara matematis X_n dipengaruhi oleh X_{n-1} dan X_{n-13} . Sedangkan lag lainnya yang tidak mencapai atau melewati signifikan itu menunjukkan tidak adanya autoregresif atau tidak memiliki pengaruh langsung pada nilai variabel target saat ini (X_n)

Sebelum melakukan peramalan ada beberapa tahap yang harus dilakukan salah satunya membagi data menjadi data pelatihan jaringan dan data pengujian jaringan.

Tabel 2. Partisi Data

| Partisi Data | Persentase | Total |
|----------------|------------|-------|
| Data Pelatihan | 70% | 124 |
| Data Pengujian | 30% | 53 |
| Total | 100 | 177 |

Selanjutnya, Perhitungan *preprocessing* data Inflasi di Provinsi Gorontalo ke-1, ke-2, ke-3, ke-176 dan ke-177 sebagai berikut :

$$\begin{aligned}
x'_1 &= \frac{(0.8(13 - 0.21))}{(13 - 0.21)} + 0.1 = 0.9 \\
x'_2 &= \frac{(0.8(12.26 - 0.21))}{(13 - 0.21)} + 0.1 = 0.8537 \\
x'_3 &= \frac{(0.8(12.66 - 0.21))}{(13 - 0.21)} + 0.1 = 0.8787 \\
&\vdots \\
&\vdots \\
x'_{176} &= \frac{(0.8(4.68 - 0.21))}{(13 - 0.21)} + 0.1 = 0.3795 \\
x'_{177} &= \frac{(0.8(3.45 - 0.21))}{(13 - 0.21)} + 0.1 = 0.3027
\end{aligned}$$

3.3 Pelatihan Jaringan GRNN

Jumlah neuron pada lapisan pola untuk melatih jaringan GRNN adalah 111, sesuai dengan jumlah vektor input data pelatihan untuk masing-masing variabel X_1 dan X_2 . Untuk mencapai hasil jaringan yang optimal, beberapa percobaan dilakukan pada tahap pelatihan dengan memodifikasi parameter (*spread*). *Spread* adalah parameter yang mengontrol seberapa luas pengaruh setiap data pelatihan dalam mempengaruhi hasil prediksi GRNN. Nilai *spread* yang lebih kecil menghasilkan pengaruh yang lebih terlokalisasi, sedangkan nilai *spread* yang lebih besar menghasilkan pengaruh yang lebih tersebar. Dalam GRNN, data pelatihan yang berada dalam jarak yang lebih dekat dengan titik yang akan diprediksi akan memiliki pengaruh yang lebih besar terhadap hasil prediksi. Eksperimen dilakukan untuk mencari nilai penyebaran GRNN yang optimal dengan menguji beberapa nilai penyebaran, yaitu 0,02; 0,03; 0,04; 0,05; 0,1. Nilai penyebaran yang menghasilkan MAPE terkecil akan dipilih sebagai nilai penyebaran yang paling optimal. Langkah pertama yang dilakukan untuk pelatihan jaringan GRNN adalah mencari jarak antara data input dan bobot dengan menggunakan jarak *Euclidean*.

$$\begin{aligned}
d_1 &= \sqrt{(0.3545 - 0.3545)^2 + (0.9 - 0.9)^2} = 0 \\
d_2 &= \sqrt{(0.3352 - 0.3545)^2 + (0.8537 - 0.9)^2} = 0.025 \\
d_3 &= \sqrt{(0.3496 - 0.3545)^2 + (0.8787 - 0.9)^2} = 0.0005 \\
&\vdots \\
d_{110} &= \sqrt{(0.1988 - 0.3545)^2 + (0.3627 - 0.9)^2} = 0.3129 \\
d_{111} &= \sqrt{(0.2307 - 0.3545)^2 + (0.3670 - 0.9)^2} = 0.2993
\end{aligned}$$

Kemudian menentukan bobot biasanya $0.8326/0.02 = 41.63$. Selanjutnya fungsi aktivasinya dapat ditentukan sebagai berikut:

$$\begin{aligned}
\theta_1 &= e^{-(41.63 \times 0)^2} = 1 \\
\theta_2 &= e^{-(41.63 \times 0.025)^2} = 0.012720922 \\
&\vdots
\end{aligned}$$

$$\theta_{111} = e^{-(41.63 \times 0.2993)^2} = 5.0264 \times 10^{-226}$$

Nilai aktivasi diatas digunakan untuk menghitung nilai pada *summation layer*, yaitu penjumlahan fungsi aktivasi (S_s) dan penjumlahan fungsi aktivasi terboboti (S_w).

$$S_s = 1 + 0.012720922 + \dots + 5.0264 \times 10^{-226} = 1.4499$$

$$S_w = 1 \times 0.3352 + 0.012720922 \times 0.3496 + \dots + 5.0264 \times 10^{-226} \times 0.2345 = 0.520932$$

Selanjutnya mencari output layer yang merupakan hasil pembagian dari penjumlahan fungsi aktivasi (S_s) dan penjumlahan fungsi aktivasi terboboti (S_w).

$$\widehat{y}_{t1} = \frac{0.520932}{1.4499} = 0.3593$$

Selanjutnya dilakukan langkah tersebut untuk menghasilkan $y_{t2} - y_{t111}$. Selanjutnya menghitung nilai *Mean Absolute Percentage Error* (MAPE) untuk mengevaluasi nilai spread pada pelatihan jaringan GRNN.

$$MAPE = \frac{1}{n} \sum_{t=1}^{11} \frac{|Y_t - \widehat{Y}_t|}{Y_t} = 8.721627601930313$$

Berdasarkan pelatihan yang dilakukan dengan rentang parameter *spread* antara 0.02 hingga 0.1, ditemukan bahwa nilai spread t, yaitu 0.02, memberikan nilai MAPE terkecil. Ini menunjukkan bahwa dalam konteks dan dataset yang digunakan dalam pelatihan jaringan GRNN, penggunaan nilai spread 0.02 menghasilkan prediksi yang paling akurat dalam hal persentase kesalahan rata-rata.

Tabel 3. Hasil Uji parameter Spread GRNN

| Uji coba ke- | Nilai <i>spread</i> | MAPE |
|--------------|---------------------|--------------------|
| 1 | 0.02 | 8.721627601930313 |
| 2 | 0.03 | 10.976545276588872 |
| 3 | 0.04 | 12.094885707938673 |
| 4 | 0.5 | 12.881124015588792 |

Parameter *spread* ini mengontrol sejauh mana pengaruh setiap data pelatihan dalam mempengaruhi hasil prediksi. Nilai *spread* yang lebih kecil memberikan pengaruh yang lebih terlokalisasi, sedangkan nilai *spread* yang lebih besar memberikan pengaruh yang lebih tersebar. Oleh karena itu, dengan menggunakan nilai *spread* 0.02, GRNN lebih fokus pada data pelatihan yang berada dalam jarak dekat dengan titik yang akan diprediksi, sehingga memungkinkan model untuk menangkap pola yang lebih halus dan menghasilkan prediksi yang lebih akurat. Selanjutnya nilai *spread* 0.02 tersebut akan digunakan pada model GRNN untuk prediksi inflasi di Provinsi Gorontalo.

Dalam jaringan ini, fungsi aktivasi radial basis digunakan. Setelah fungsi aktivasi terbentuk, langkah berikutnya adalah masuk ke lapisan selanjutnya, yaitu lapisan penjumlahan (*summation layer*). Di lapisan ini, terdapat dua tahap pemrosesan. Tahap pertama melibatkan penjumlahan aritmatika terhadap fungsi aktivasi (S_s) dan penjumlahan terbobot (S_w), di mana bobot pada lapisan ini setara dengan nilai vektor target. Selanjutnya, masuk ke lapisan output, di mana output dihasilkan dari pembagian nilai penjumlahan terbobot dan nilai penjumlahan fungsi aktivasi, menjadi nilai keluaran dari lapisan output jaringan GRNN. Pada proses pelatihan, observasi pertama masing-masing variabel X_1 , X_2 , dan Y . Untuk selanjutnya dilakukan proses yang sama sehingga didapatkan 111 output yang sesuai dengan jumlah vektor input variabel X . Berikut ini adalah grafik perbandingan antara data aktual dengan hasil prediksi pelatihan jaringan GRNN.

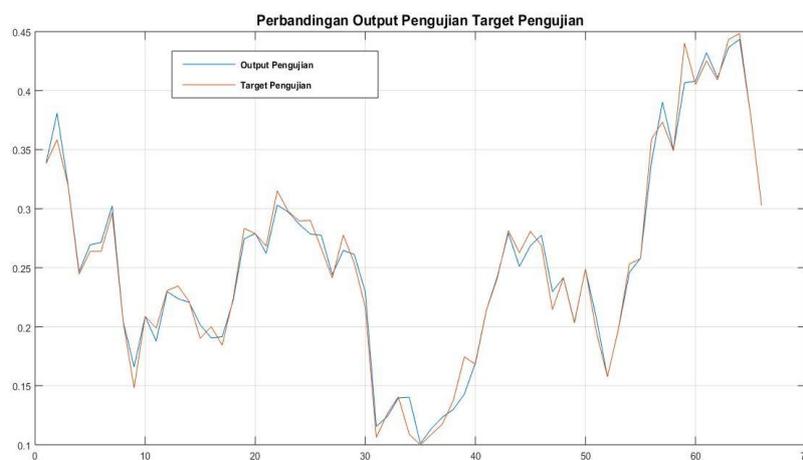


Gambar 3. Grafik Data Pelatihan GRNN

Dalam Gambar 3, kurva biru mewakili hasil prediksi Inflasi pada tahap pelatihan GRNN, sementara kurva merah menunjukkan data aktual Inflasi di Provinsi Gorontalo. Terlihat bahwa grafik prediksi inflasi dari jaringan GRNN mendekati data aktual atau kenyataannya. Prediksi ini dilakukan dengan menggunakan parameter spread sebesar 0,02, menghasilkan nilai MAPE sekitar 8,72%, yang menunjukkan bahwa pelatihan jaringan GRNN memiliki tingkat akurasi sekitar 91,28%.

3.4 Pengujian Jaringan GRNN

Setelah selesai tahap pelatihan jaringan GRNN selanjutnya pengujian jaringan GRNN diawali dengan penginputan data pengujian yang berjumlah 66 data untuk masing-masing variabel X_1 , X_2 dan y , pada jaringan GRNN yang telah terbentuk menggunakan spread 0,02. Berikut ini adalah perbandingan hasil peramalan inflasi aktual pada tahap pengujian menggunakan jaringan GRNN.



Gambar 4. Grafik Data Pengujian GRNN

Berdasarkan Gambar 4, terlihat bahwa grafik pergerakan inflasi yang diprediksi oleh jaringan GRNN hampir mirip dengan data aktual, meskipun rentang nilai terlihat sedikit jauh. Prediksi ini dilakukan dengan menggunakan parameter spread sebesar 0,02 dan menghasilkan nilai MAPE sekitar 3,24%, menandakan bahwa pelatihan jaringan GRNN mencapai tingkat akurasi sekitar 96,76%.

3.5 Peramalan Inflasi di Provinsi Gorontalo

Proses peramalan inflasi pada jaringan GRNN dirancang dengan nilai penyebaran n sebesar 0,02 yang telah melewati tahap pelatihan dan pengujian. Peramalan dilaksanakan dengan memanfaatkan input X_{t-1} dan X_{t-13} , yang masing-masing merujuk pada data bulan April 2023 dan April 2022, serta memanfaatkan informasi bobot yang diperoleh selama tahap pelatihan. Tahap awal

peramalan ini melibatkan penghitungan jarak antara data input dan bobot menggunakan metode jarak Euclidean.

$$d_1 = \sqrt{(0.9 - 0.3026)^2 + (0.3545 - 0.2532)^2} = 0.367092$$

$$d_2 = \sqrt{(0.8537 - 0.3026)^2 + (0.3352 - 0.2532)^2} = 0.310382$$

$$d_3 = \sqrt{(0.8787 - 0.3026)^2 + (0.3496 - 0.2532)^2} = 0.341148$$

$$\vdots$$

$$d_{110} = \sqrt{(0.3627 - 0.3026)^2 + (0.1988 - 0.2532)^2} = 0.006562$$

$$d_{111} = \sqrt{(0.3670 - 0.3026)^2 + (0.2307 - 0.2532)^2} = 0.004655$$

Kemudian bobot biasanya $0.8326/0.02 = 41.63$. Selanjutnya fungsi aktivasinya dapat ditentukan sebagai berikut:

$$\theta_1 = e^{-(41.63 \times 0.367092)^2} = 5.0794 \times 10^{-277}$$

$$\theta_2 = e^{-(41.63 \times 0.310382)^2} = 2.4494 \times 10^{-234}$$

$$\theta_{111} = e^{-(41.63 \times 0.004655)^2} = 3.1337 \times 10^{-4}$$

Nilai aktivasi diatas digunakan untuk menghitung nilai pada *summation layer*, yaitu penjumlahan fungsi aktivasi (Ss) dan penjumlahan fungsi aktivasi terboboti (Sw).

$$Ss = 5.0794 \times 10^{-277} + 2.4494 \times 10^{-234} + \dots + 3.1337 \times 10^{-4} = 0.26327$$

dan

$$Sw = 5.0794 \times 10^{-277} \times 0.3352 + 2.4494 \times 10^{-234} \times 0.3496 + \dots + 3.1337 \times 10^{-4} \times 0.2345 = 7.211 \times 10^{-2}$$

Selanjutnya mencari *output layer* yang merupakan hasil pembagian dari penjumlahan fungsi aktivasi (Ss) dan penjumlahan fungsi aktivasi terboboti (Sw).

$$\hat{y}_t = \frac{0.26327}{0.07211} = 0.2740$$

Langkah selanjutnya adalah denormalisasi nilai *output layer* atau prediksi bulan Mei tersebut. Hasil peramalan inflasi pada bulan Mei setelah dilakukan proses denormalisasi adalah 2.99%. Untuk peramalan bulan-bulan selanjutnya dapat dilakukan dengan mengulangi langkah-langkah tersebut. Hasil jaringan GRNN ini menghasilkan peramalan Inflasi di Provinsi Gorontalo pada bulan Mei hingga Desember Tahun 2023. Berikut tabel hasil peramalan tersebut:

Table 4. Hasil Peramalan Inflasi di Provinsi Gorontalo

| Bulan | Hasil Peramalan (%) |
|-----------|---------------------|
| Mei | 2.99 % |
| Juni | 3.02 % |
| Juli | 4.21 % |
| Agustus | 4.32 % |
| September | 4.04 % |
| Oktober | 5.34 % |
| November | 5.47 % |
| Desember | 5.64 % |

4. Kesimpulan

Berdasarkan penelitian yang telah dilakukan Perkembangan tingkat inflasi di provinsi Gorontalo pada tahun 2023 periode Mei sampai desember menghasilkan tingkat akurasi 96,76% dengan MAPE sebesar 3,24%. Pada periode ini menunjukkan tren yang baik meskipun masi cenderung naik dimana inflasi tertinggi terjadi pada bulan Desember sebesar 5,64% dan yang terendah pada bulan Mei sebesar 2,99% hal ini menunjukkan ketidakstabilan perekonomian di provinsi Gorontalo pemerintah perlu melakukan kebijakan guna menjaga kestabilan perekonomian.

Referensi

- [1] A. Dajan, *Pengantar Metode Statistik*. Jakarta: LP3ES, 1995.
- [2] A. Wanto and A. P. Windarto, "Analisis Prediksi Indeks Harga Konsumen Berdasarkan Kelompok Kesehatan Dengan Menggunakan Metode Backpropagation," *Sinkron*, vol. 2, no. 2, pp. 37–43, 2017.
- [3] W. A. Marlina, S. Susiana, E. N, and F. A. Ahmad, "Forecasting technique using time sequence: model penentuan volume produksi Sanjai di UKM Rina Payakumbuh," *J. Manaj.*, vol. 9, no. 2, p. 187, Dec. 2018, doi: 10.32832/jm-uika.v9i2.1567.
- [4] R. E. Caraka, H. Yasin, and A. Prahutama, "Pemodelan General Regression Neural Network (GRNN) pada Data Return Indeks Harga Saham Euro 50," *J. Gaussian*, vol. 4, no. 2, 2015.
- [5] E. F. Rahayuningtyas, G. Wasis Wicaksono, and D. R. Chandranegara, "Prediction of Yuan to IDR Exchange Rate using General Regression Neural Network," in *2021 International Conference on Computer Science, Information Technology, and Electrical Engineering (ICOMITEE)*, Oct. 2021, pp. 1–6, doi: 10.1109/ICOMITEE53461.2021.9650304.
- [6] F. A. Y. Putri, "Studi Komparasi Peramalan Harga Minyak Mentah Menggunakan Metode Generalized Regression Neural Network dan Feed Forward Neural Network," Universitas Islam Indonesia, 2018.
- [7] M. Alkaff and Y. Sari, "Penerapan Generalized Regression Neural Networks untuk Memprediksi Produksi Padi Terhadap Perubahan Iklim," *J. Teknol. Rekayasa*, vol. 2, no. 2, p. 117, Dec. 2017, doi: 10.31544/jtera.v2.i2.2017.117-124.
- [8] L. P. W. Adnyani and S. Subanar, "General Regression Neural Network (GRNN) pada Peramalan Kurs Dolar dan Indeks Harga Saham Gabungan (IHSG)," *Fakt. Exacta*, vol. 8, no. 2, 2015.
- [9] Z. Izzah, "Sistem Peramalan Jumlah Pengunjung Wisata Religi Sunan Drajat Dengan Metode Least Square," Universitas Islam Lamongan, 2021.