

IMPLEMENTASI METODE BACKPROPAGATION NEURAL NETWORK DALAM MERAMALKAN TINGKAT INFLASI DI INDONESIA

Ahmad Rizki Wiranto

Matematika, FMIPA, Universitas Lampung

Eri Setiawan

Matematika, FMIPA, Universitas Lampung

Aang Nuryaman

Matematika, FMIPA, Universitas Lampung

Mustofa Usman

Matematika, FMIPA, Universitas Lampung

email korespondensi: eristatis@gmail.com

Abstrak

Peramalan adalah usaha untuk memperkirakan kejadian di masa depan dengan mengacu pada trend dari data atau data historis. Beberapa metode yang umum digunakan dalam peramalan data deret waktu termasuk *Autoregressive Integrated Moving Average* (ARIMA), *Exponential Smoothing*, dan *Seasonal Autoregressive Integrated Moving Average* (SARIMA). Namun, teknik-teknik peramalan tersebut memiliki kelemahan atau kekurangan, seperti membutuhkan data yang memiliki sifat stasioner dan tingkat akurasi yang terkadang kurang baik. Peneliti banyak yang mengadopsi metode Jaringan Saraf Tiruan untuk mengatasi kelemahan tersebut, seperti *Backpropagation Neural Network*. Metode *Backpropagation Neural Network* terbukti sangat efektif dalam melakukan peramalan di bidang ekonomi. Permasalahan ekonomi yang dianggap menjadi permasalahan besar dan belum teratasi sampai saat ini yaitu inflasi. Dalam penelitian ini, data yang digunakan yaitu data inflasi dari periode Januari 2000 hingga Oktober 2022 dengan menggunakan metode *Backpropagation Neural Network* untuk meramalkannya. Hasil penelitian menunjukkan bahwa pembagian data 50% untuk pelatihan (*training*) dan 50% untuk pengujian (*testing*) merupakan proporsi pembagian terbaik, dengan menggunakan fungsi aktivasi sigmoid biner serta arsitektur jaringan 12-21-1. Nilai *Mean Square Error* (MSE) pada tahap pelatihan adalah 0.00067535, sedangkan pada tahap pengujian adalah 0.0767. Berdasarkan peramalan, inflasi tertinggi diperkirakan terjadi inflasi sebesar 0.5579 pada bulan Oktober 2023, sementara inflasi terendah sebesar 0.203 yang diperkirakan terjadi pada bulan Februari 2023.

Kata Kunci: Backpropagation Neural Network, Deret Waktu, Jaringan Syaraf Tiruan, Inflasi, dan Peramalan

Abstract

Forecasting is an attempt to estimate future events by referring to trends from historical data or data. Several methods commonly used in forecasting time series data include Autoregressive Integrated Moving Average (ARIMA), Exponential Smoothing, and Seasonal Autoregressive Integrated Moving Average (SARIMA). However, these forecasting techniques have weaknesses or deficiencies, such as requiring data that is stationary and sometimes the level of accuracy is not good. Many researchers have adopted the Artificial Neural Network method to overcome these weaknesses, such as the Backpropagation Neural Network. The Backpropagation Neural Network method has proven to be very effective in forecasting in the economic field. The economic problem that is considered to be a big problem and has not been resolved to date is inflation. In this study, the data used is inflation data from January 2000 to October 2022 using the Backpropagation Neural Network method to predict it. The results showed that 50% of data sharing for training and 50% for testing is the best proportion of sharing, using the binary sigmoid activation function and 12-21-1 network architecture. The Mean Square Error (MSE) value at the training stage is 0.00067535, while at the testing stage it is 0.0767. Based on forecasts, the highest inflation is expected to occur in October 2023 of 0.5579, while the lowest inflation is expected to occur in February 2023 of 0.203.

Keywords: Backpropagation Neural Network, Time Series, Neural Network, Inflation, and Forecasting

PENDAHULUAN

Peramalan merupakan permasalahan yang relevan dalam berbagai bidang, termasuk bisnis, industri, ilmu lingkungan, ilmu sosial, pemerintahan, ekonomi, kedokteran, politik, dan keuangan (Montgomery *et al.*, 2015). Beberapa metode yang umum digunakan untuk memprediksi data deret waktu meliputi *Autoregressive Integrated Moving Average (ARIMA)*, *Exponential Smoothing*, *Single Moving Average*, *Double Exponential Smoothing*, dan *Seasonal Autoregressive Integrated Moving Average (SARIMA)*. Tetapi, Teknik-teknik dalam peramalan yang telah disebutkan tersebut memiliki beberapa kekurangan, seperti kebutuhan akan data yang stasioner serta tingkat keakuratan yang terkadang kurang baik (Susilokarti *et al.*, 2015).

Untuk mengatasi kelemahan yang mungkin ada pada metode-metode yang telah disebutkan sebelumnya, banyak peneliti yang memilih untuk beralih untuk menerapkan metode Jaringan Syaraf Tiruan (JST). Metode ini memiliki tahapan pelatihan yang dapat meningkatkan hasil peramalan dan dapat digunakan pada data runtun waktu yang tidak stasioner. Terdapat berbagai jenis jaringan saraf tiruan yang dapat digunakan, salah satunya adalah *Backpropagation Neural Network (BPNN)*. Menurut penelitian yang dilakukan oleh Ramadhona *et al.* (2018), metode BPNN sangat efektif dalam memprediksi pergerakan di bidang ekonomi.

Inflasi merupakan salah satu tantangan perekonomian di Indonesia bahkan dunia yang menakutkan serta sangat kompleks. Pemerintah harus memprioritaskan pengendalian inflasi karena dampak negatif yang ditimbulkannya, seperti memperburuk distribusi pendapatan, menurunkan tabungan dalam negeri, menyebabkan kerugian dalam dunia perdagangan, mendorong tingginya pinjaman dana dari negara lain, dan berpotensi memicu kekacauan dalam bidang politik. Berdasarkan dampak yang dapat ditimbulkan oleh inflasi, maka diperlukan langkah-langkah untuk mencegah inflasi menjadi hambatan dalam proses pembangunan (Sutawijaya, 2012). Oleh karena itu, pemerintah sangat membutuhkan prediksi tingkat inflasi agar dapat memperoleh informasi tentang perkiraan tingkat inflasi di masa depan. Faktor ini dianggap menjadi pertimbangan yang krusial dalam proses pengambilan keputusan.

Menurut Achmalia, dkk. (2020), metode *Backpropagation Neural Network (BPNN)* memiliki tingkat akurasi lebih tinggi daripada metode *Recurrent Neural Network* dalam meramalkan penjualan semen dengan laju pembelajaran sebesar 0.002 serta fungsi aktivasi logsig.

Dari riset yang dikerjakan oleh Purnawansyah, dkk. (2019), metode *Backpropagation Neural Network (BPNN)* diterapkan dalam memprediksikan tingkat inflasi di Kota Samarinda pada rentang tahun 2012-2017 dengan menggunakan *trainlm* sebagai fungsi pembelajarannya, sedangkan logsig dan *purelin* fungsi aktivasi yang digunakan dalam riset tersebut. *Learning rate* yang digunakan adalah 0.1, dan hasil evaluasi menggunakan *Mean Squared Error (MSE)* menunjukkan nilai sebesar 0.00000424. Penelitian lain yang dilakukan oleh Aini, dkk. (2019) menggunakan metode *Backpropagation Neural Network (BPNN)* untuk meramalkan produksi minyak kelapa sawit. Fungsi pembelajaran yang digunakan adalah *trainlm*, dengan fungsi aktivasi logsig dan *purelin*. Hasil penelitian menunjukkan bahwa *Mean Squared Error (MSE)* yang diperoleh adalah sebesar 0.0069.

Metode *Backpropagation Neural Network* dipilih karena telah terbukti akurat dalam meramalkan berbagai masalah ekonomi, seperti yang dijelaskan oleh Susanti, dkk. (2011). Metode ini juga dianggap memiliki kapabilitas yang cukup cepat dalam hal mengidentifikasi informasi yang terdapat dari data serta adaptasi yang baik dalam menuntaskan berbagai permasalahan, seperti yang dicatat oleh Thakur, dkk. (2016). Dalam penelitian ini, akan diimplementasikannya metode *Backpropagation Neural Network* untuk meramalkan inflasi di Indonesia. *Learning rate* yang digunakan adalah 0.5, dengan fungsi aktivasi sigmoid biner dan sigmoid bipolar. Selain itu, penelitian juga akan memperhatikan pengaruh proporsi pembagian antara data latih dan data uji.

KAJIAN TEORI

NORMALISASI DAN DENORMALISASI

Normalisasi adalah proses yang dilakukan pada data asli untuk mengubahnya menjadi rentang tertentu sebelum digunakan (Budianita & Prijodiprodjo, 2013). Proses normalisasi pada data yang akan digunakan bertujuan agar didapatkan

rentang data yang relative seragam, tetapi tetap mempertahankan informasi yang terkandung dalam data aslinya. Chamidah dan Salamah (2012) menyatakan bahwasanya metode min-max dianggap dapat memberikan kontribusi dalam nilai efektivitas yang lebih baik dalam hal kecepatan konvergensi dan akurasi. Metode ini memiliki kemampuan untuk mencapai akurasi rata-rata hingga 96.86%. Menurut Hidayat, dkk. (2012), Denormalisasi adalah proses yang digunakan untuk merestorasi data yang telah dinormalisasi ke nilai aslinya. Hal ini dilakukan setelah proses peramalan atau prediksi selesai dilakukan. Tujuannya adalah untuk memperoleh hasil peramalan atau prediksi yang dapat dimengerti oleh pengguna data yang awam atau tidak terbiasa dengan data yang telah dinormalisasi. Proses denormalisasi sangat penting dalam penggunaan data karena dapat memudahkan pengambilan keputusan dan tindakan berdasarkan hasil peramalan atau prediksi yang diperoleh.

Bentuk persamaan dari normalisasi sebagai berikut:

$$x_i^* = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (1)$$

Sedangkan persamaan dari denormalisasi sebagai berikut:

$$x_i = x_i^* (\max(x) - \min(x)) + \min(x) \quad (2)$$

Dimana x_i^* merupakan data sesudah denormalisasi ke- i , x_i merupakan data ke- i , $\min(x)$ sebagai nilai minimum dari data, dan $\max(x)$ sebagai nilai maksimum dari data.

BACKPROPAGATION NEURAL NETWORK (BPNN)

Backpropagation Neural Network (BPNN) merupakan suatu jenis jaringan saraf tiruan yang termasuk dalam pembelajaran terpantau (*supervised learning*) dan menggunakan *perceptron multilayer*. BPNN memiliki dua arah, yaitu maju (*forward*) dan mundur (*backward*). Adapun lapisan-lapisan yang terdapat pada algoritma *backpropagation* yaitu *input layer*, *hidden layer*, dan *output layer*. Dimana lapisan ini terletak pada tahapan pelatihan. Salah satu pengaruh penting dari adanya lapisan tersembunyi (*hidden layer*) dalam BPNN adalah dapat mengurangi tingkat kesalahan (*error*) dibandingkan dengan model yang hanya memiliki satu lapisan (*single layer*) atau tanpa lapisan tersembunyi. Memperbarui serta

penyesuaian bobot (*weights*) yang digunakan dalam proses pelatihan merupakan fungsi dari lapisan tersembunyi atau *hidden layer*. Sehingga manfaat dari adanya tahapan dalam penyesuaian bobot ialah agar *input-input* dapat mencapai nilai bobot baru yang mendekati target yang diinginkan. Oleh karena itu, lapisan tersembunyi memiliki peran penting dalam meningkatkan performa dan akurasi BPNN dalam melakukan tugas prediksi atau peramalan, seperti yang dijelaskan oleh Afrianto, dkk. (2013).

Arhami (2020) mengungkapkan bahwa terdapat beberapa tahap yang perlu dilakukan dalam menjalankan algoritma *Backpropagation Neural Network* pada jaringan saraf tiruan.

1. Langkah pertama adalah melakukan inisialisasi bobot, menentukan *target error*, jumlah maksimum epoch, serta *learning rate* (α)

Fase I : Propogasi Maju (*Forward Propagation*)

2. Setiap unit pada lapisan masukan menerima sinyal masukan x_i , dengan $i = 1, 2, 3, \dots, n$ dan kemudian semua unit yang ada pada lapisan tersembunyi berikutnya akan menerima terusan dari sinyal-sinyal. Dengan kata lain, setiap unit pada lapisan masukan bertindak sebagai pemasok sinyal ke lapisan tersembunyi, mengirimkan sinyal masukan yang diterimanya ke setiap unit pada lapisan tersembunyi tersebut.
3. Setiap unit di lapisan tersembunyi, yang ditandai sebagai z_j dengan $j = 1, 2, 3, \dots, p$, melakukan penjumlahan sinyal input yang telah dibobotkan.

$$z_{in_j} = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (3)$$

Setelah itu, fungsi aktivasi yang telah ditentukan akan digunakan dalam menghitung nilai keluaran.

$$z_j = f(z_{in_j}) \quad (4)$$

Kemudian lapisan keluaran atau *output layer* akan dikirimkan sebuah sinyal dimana sinyal tersebut dikirimkan untuk semua unit.

4. Setiap unit di lapisan keluaran, yang ditandai sebagai y_k dengan $k = 1, 2, 3, \dots, m$, sinyal masukan dari masing-masing lapisan akan dijumlahkan bobotnya.

$$y_{in_k} = w_{0k} + \sum_{j=1}^p z_j w_{jk} \quad (5)$$

Selanjutnya, nilai keluaran dihitung dengan menggunakan fungsi aktivasi.

$$y_k = f(y_{in_k}) \quad (6)$$

Fase II : Propagasi Mundur (Backpropagation)

5. Setiap unit keluaran, yang ditandai sebagai y_k dengan $k = 1,2,3, \dots, m$, dimana pola dari *input* proses pembelajaran akan menerima sebuah target pola yang saling memiliki hubungan dan kemudian dihitung informasi *error*.

$$\delta_k = (t_k - y_k) f'(y_{in_k}) \quad (7)$$

Setelah itu, nilai w_{jk} akan diperbarui dengan cara mendapatkan terlebih dahulu perhitungan dari perubahan yang terjadi pada bobot:

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (8)$$

Hitunglah juga perubahan yang terjadi pada nilai dari bias. Dimana nilai bias ini akan dipergunakan dalam memperbarui nilai w_{0k} :

$$\Delta w_{0k} = \alpha \delta_k \quad (9)$$

6. Setiap unit di lapisan tersembunyi z_j dengan $j = 1,2,3, \dots, p$, dimana unit-unit yang terletak pada lapisan tersembunyi akan dijumlahkan sehingga mendapatkan delta *input*-nya:

$$\delta_{in_j} = \sum_{k=1}^m \delta_k w_{jk} \quad (10)$$

Untuk menghitung nilai dari informasi kesalahan digunakan perkalian antara sinyal masukan yang diterima oleh lapisan tersembunyi dari lapisan masukan dengan turunan dari fungsi aktivasi yang telah ditentukan. Hal ini dilakukan untuk menentukan sejauh mana nilai kesalahan atau perbedaan antara output yang telah ditentukan (target) dengan nilai output yang diperoleh dari jaringan. Dengan mengalikan nilai masukan dengan turunan fungsi aktivasi, kita dapat menghitung tingkat kontribusi setiap unit pada lapisan tersembunyi terhadap kesalahan yang terjadi dalam jaringan.

$$\delta_j = \delta_{in_j} f'(z_{in_j}) \quad (11)$$

Menghitung perubahan dari nilai bobot yang nantinya akan digunakan untuk memperbarui v_{ij} dengan rumus:

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

Tentukan juga perubahan dari nilai bias. Dimana perubahan nilai bias ini yang akan digunakan dalam memperbarui nilai dari v_{0j} :

$$\Delta v_{0j} = \alpha \delta_j \quad (13)$$

Fase III : Perubahan Bobot

7. Setiap unit output y_k dengan $k = 1,2,3, \dots, m$ akan mengalami pembaharuan pada nilai bias beserta dengan nilai bobotnya (dengan $j = 1,2,3, \dots, p$):

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

$$w_{0k}(\text{baru}) = w_{0k}(\text{lama}) + \Delta w_{0k} \quad (15)$$

Setiap unit hidden z_j (dengan $j = 1,2,3, \dots, p$) juga akan mengalami pembaruan pada bias serta bobotnya (dengan $i = 1,2,3, \dots, n$):

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (16)$$

$$v_{0j}(\text{baru}) = v_{0j}(\text{lama}) + \Delta v_{0j} \quad (17)$$

8. Perhatikan apakah kondisi dimana proses penghentian sampai dengan tahapan ke-7 sudah tercapai atau belum. Jika proses dianggap belum tercapai pada target yang telah ditentukan, maka Langkah yang harus dilakukan yaitu melanjutkan kembaliproses Langkah 2 sampai 7 akan diulang sampai kepada kondisi dimana penghentian terpenuhi.

Agar jumlah neuron yang terdapat pada lapisan tersembunyi tidak terlalu sedikit atau banyak, maka perlu dilakukan perhatian khusus. Hal ini karena jika jumlah neuron terlalu sedikit, dapat menyebabkan kondisi *underfitting*. Kondisi ini terjadi disebabkan oleh pendeteksian sinyal yang terdapat pada data yang kompleks tidak dapat dilakukan secara maksimal oleh neuron yang terdapat pada lapisan tersembunyi. Neuron tersebut tidak mampu mendeteksi secara baik karena jumlahnya yang terlalu sedikit. Tetapi, jika jumlah neuron pada lapisan tersembunyi jumlahnya kebanyakan, dapat menyebabkan kondisi dimana

kapasitas yang terlalu besar pada jaringan, sehingga mengalami kesulitan dalam memproses informasi. Dimana kondisi tersebut dinamakan kondisi *overfitting*. Namun, terkadang jumlah informasi yang terbatas dalam data latih tidak mencukupi untuk melatih setiap neuron yang ada dalam lapisan tersembunyi (*hidden layer*).

Untuk menentukan jumlah neuron yang tepat dalam lapisan tersembunyi, dapat digunakan aturan yang dikenal sebagai "Jeff Heaton rule" yang diusulkan oleh Jeff Heaton pada tahun 2017. Aturan ini membantu dalam menentukan jumlah optimal neuron dalam lapisan tersembunyi berdasarkan jumlah fitur masukan (*input*) dan fitur keluaran (*output*) dalam data yang digunakan. Perlu dicatat bahwa aturan ini bersifat empiris dan dapat bervariasi tergantung pada kasus yang sedang ditangani. Oleh karena itu, penyesuaian dan eksperimen perlu dilakukan untuk menemukan jumlah neuron yang paling sesuai dengan masalah yang dihadapi.

- a. Banyaknya neuron dalam lapisan tersembunyi berada di antara jumlah neuron dalam lapisan keluaran dan lapisan masukan.
- b. Banyaknya neuron dalam lapisan tersembunyi biasanya sekitar $\frac{2}{3}$ dari jumlah neuron dalam lapisan masukan ditambah jumlah neuron dalam lapisan keluaran.

$$\frac{2}{3}(\text{jumlah input layer} + \text{jumlah output layer}) \quad (18)$$
- c. Banyaknya suatu neuron dalam lapisan tersembunyi biasanya sebanyak kurang dari dua kali lipat jumlah neuron dalam lapisan masukan.

FUNGSI AKTIVASI

Dalam metode *Backpropagation Neural Network*, digunakan fungsi aktivasi yang memenuhi beberapa syarat. Fungsi aktivasi harus kontinu, mudah untuk didiferensialkan, dan merupakan fungsi monotonik tidak menurun. Kontinuitas fungsi aktivasi memastikan bahwa output dari jaringan dapat berubah secara halus dalam respons terhadap perubahan input. Sifat diferensial mudah memungkinkan perhitungan perubahan bobot dan bias dengan menggunakan aturan rantai dalam algoritma *backpropagation*. Sementara itu, sifat monotonik tidak menurun memastikan bahwa semakin besar *input*, semakin besar pula *output*-nya.

Syarat-syarat ini memungkinkan algoritma *backpropagation* untuk menghitung gradien dan melakukan penyesuaian bobot secara efisien selama proses pelatihan jaringan. Dengan menggunakan fungsi aktivasi yang memenuhi syarat ini, jaringan dapat belajar dan menyesuaikan bobotnya secara efektif untuk mengoptimalkan kinerja dan akurasi dalam tugas yang diberikan.

Fungsi aktivasi sigmoid biner dan fungsi aktivasi sigmoid bipolar merupakan contoh beberapa fungsi aktivasi yang sering digunakan dalam penerapan metode *Backpropagation Neural Network*. Nilai dari output atau keluaran yang berada pada interval 0 sampai dengan 1 merupakan ciri dari fungsi aktivasi sigmoid biner. Berikut merupakan rumus dari fungsi aktivasi sigmoid biner (Gema & Kartika, 2018):

$$y = f(x) = \frac{1}{1+e^{-x}} \quad (19)$$

$$f'(x) = \frac{e^{-x}}{(1+e^{-x})^2} = f(x)[1 - f(x)] \quad (20)$$

Sedangkan apabila nilai *output*-nya memiliki rentang nilai antara -1 sampai 1, maka fungsi tersebut ialah fungsi aktivasi sigmoid bipolar.

$$y = f(x) = \frac{1-e^{-x}}{1+e^{-x}} \quad (21)$$

$$f'(x) = \frac{2e^{-x}}{(1+e^{-x})^2} = \frac{1}{2}[1 + f(x)][1 - f(x)] \quad (22)$$

MEAN SQUARE ERROR (MSE)

Mean Squared Error (MSE) merupakan suatu perhitungan yang digunakan dalam mengukur rata-rata dari kuadrat yang diperoleh antara selisih nilai yang diharapkan dengan nilai hasil keluaran dari prediksi. Semakin rendah nilai yang didapatkan dari perhitungan MSE, maka hasil prediksi yang diperoleh akan dianggap semakin akurat.

$$MSE = \frac{1}{M} \sum_{t=1}^M (X_t - \hat{X}_t)^2 \quad (23)$$

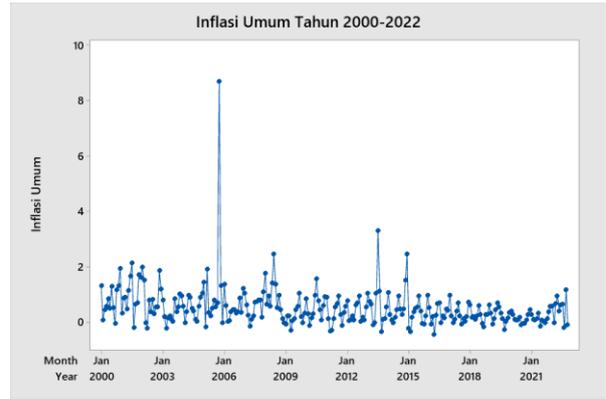
Dimana M nilai dari periode deret waktu, \hat{X}_t nilai hasil prediksi, dan X_t merupakan nilai observasi data, \hat{X}_t nilai hasil prediksi.

METODE

Data yang bersumberkan dari laman resmi Badan Pusat Statistik merupakan data yang digunakan dalam kajian ini. Data dimulai dari periode 2000

tepatnya pada bulan Januari sampai dengan Oktober 2022, merupakan data Inflasi Umum yang terjadi di Indonesia.

Diagram alur berikut ini menyajikan tahapan yang dilakukan dalam menganalisis data menggunakan metode *Backpropagation Neural Network* untuk meramalkan tingkat inflasi.



Gambar 1. Plot Data Inflasi

Dari Gambar 1 terlihat bahwa data inflasi umum memiliki nilai minimum sebesar -0,45% yang terjadi pada April 2016 dan nilai maksimumnya terjadi pada Oktober 2005 sebesar 8,7%. Selain itu, plot pada Gambar 1 menunjukkan terjadinya fluktuasi pada data inflasi umum di Indonesia dari Januari 2000 hingga Oktober 2022.

PROSES PELATIHAN

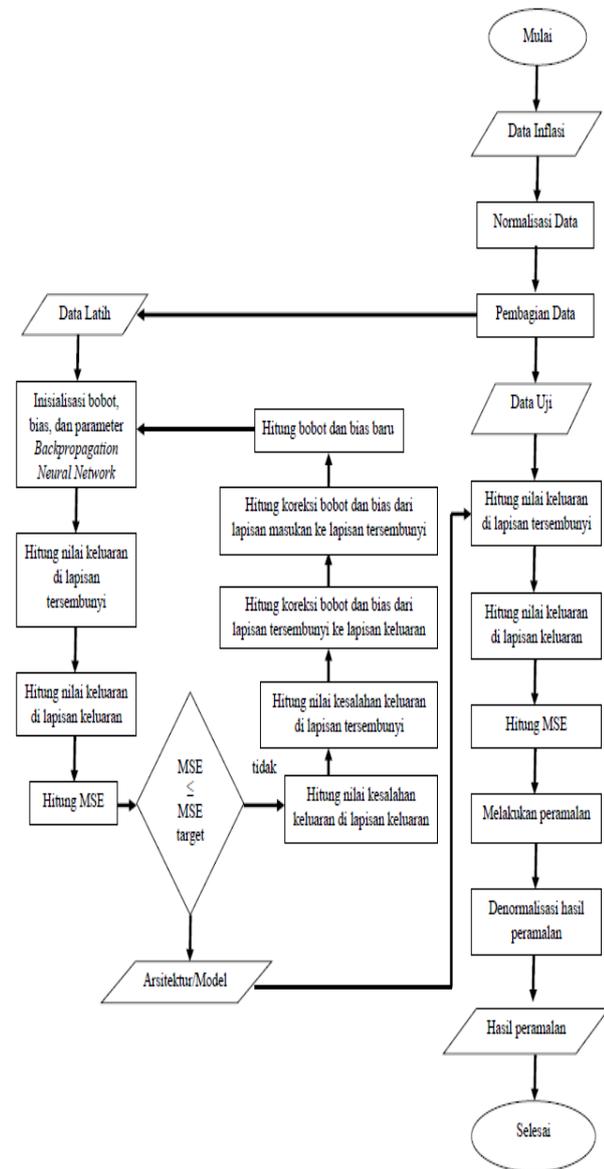
Dalam tahapan pelatihan menggunakan metode *Backpropagation Neural Network*, nilai dari parameter yang digunakan disajikan dalam Tabel 1.

Tabel 1. Parameter Jaringan

No	Parameter	
1	Fungsi Aktivasi	<i>Sigmoid Biner</i> dan <i>Sigmoid Bipolar</i>
2	Maksimum Iterasi	5000
3	Target Error	0,001
4	Laju Pembelajaran	0,5
5	Hidden Layer	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23

Dalam proses pelatihan memiliki tujuan agar dapat mengenal serta mengidentifikasi pola data yang nantinya akan diekstrapolasi polanya kedalam data yang baru untuk dilakukan pengujian serta untuk peramalan. Pada proses ini dilihat *Mean Square Error* (MSE) terkecil berdasarkan fungsi sigmoid bipolar (*tansig*) serta fungsi aktivasi sigmoid biner (*logsig*). Selain itu akan dilihat pula perbandingan MSE berdasarkan pembagian data serta jumlah neuron yang terdapat pada lapisan tersembunyi.

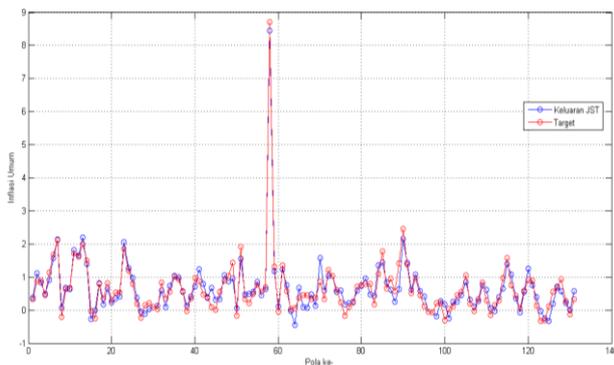
Berdasarkan perbandingan MSE yang dihasilkan dari proses pelatihan, ditemukan bahwa saat menggunakan pembagian data uji sebesar 20% serta data latih sebesar 80%, diperoleh MSE sebesar



HASIL DAN PEMBAHASAN

Berikut disajikan plot pada periode Januari 2000 - Oktober 2022 dari data inflasi di Indonesia.

0,00081987. Sementara itu, saat menggunakan pembagian data uji sebesar 30% serta data latih sebesar 70%, diperoleh MSE sebesar 0,0007517. Pembagian data uji sebesar 40% sertadata latih sebesar 60%, menghasilkan MSE sebesar 0,00067708. Selanjutnya, pada pembagian data uji sebesar 50% data latih sebesar 50%, diperoleh MSE sebesar 0,00067535. Oleh karena itu, untuk proses selanjutnya, akan digunakan 21 neuron pada *hidden layer* serta fungsi aktivasi sigmoid biner dan pembagian data uji sebesar 50% dan proporsi data latih sebesar 50%.



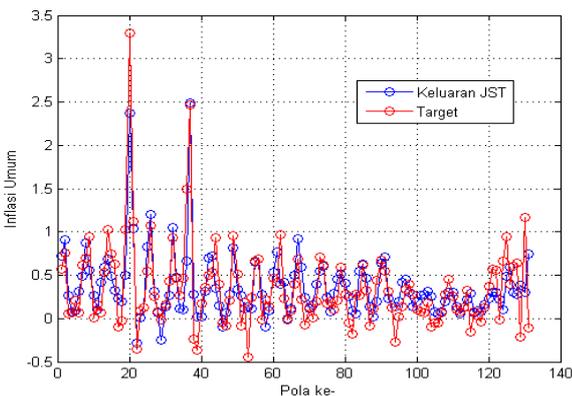
Gambar 2. Keluaran dan Target Proses Pelatihan

PROSES PENGUJIAN

Setelah didapatkan arsitektur terbaik dari proses pelatihan, maka akan dilakukan proses pengujian pada data uji menggunakan arsitektur terbaik dari metode *Backpropagation Neural* adalah arsitektur dengan 1 neuron pada *output layer*, 21 neuron pada *hidden layer* serta neuron pada *input layer* sebanyak 12 neuron

$$MSE = \frac{1}{131} \sum_{t=1}^{131} (X_t - \hat{X}_t)^2 = 0.0767$$

Diperoleh bahwa MSE dari proses pengujian yaitu 0,0767. Berikut disajikan grafik perbandingan antara nilai target asli dengan keluaran pada Gambar 3.



Gambar 3. Keluaran dan Target Proses Pengujian

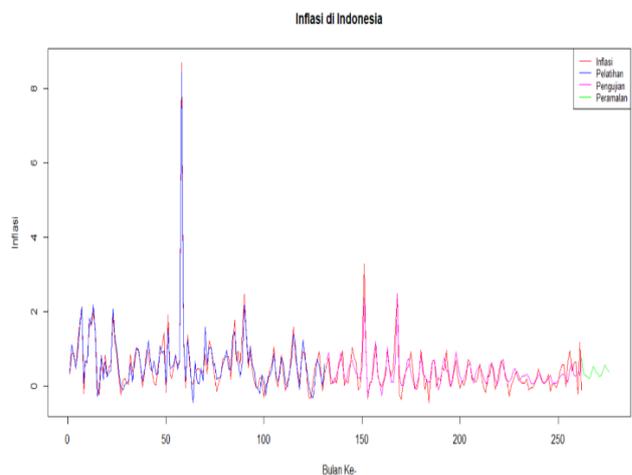
TAHAPAN PERAMALAN

Setelah dilakukan proses pelatihan dan pengujian, maka tahapan selanjutnya adalah melakukan peramalan menggunakan arsitektur yang telah di dapat. Berikut merupakan hasil peramalan tingkat inflasi di Indonesia periode November-Desember 2022, dan Januari-Desember 2023.

Tabel 2. Hasil Peramalan

No	Periode	Hasil Ramalan
1	November 2022	0,3251
2	Desember 2022	0,2860
3	Januari 2023	0,2563
4	Februari 2023	0,2030
5	Maret 2023	0,3520
6	April 2023	0,5132
7	Mei 2023	0,3937
8	Juni 2023	0,3311
9	Juli 2023	0,2487
10	Agustus 2023	0,2955
11	September 2023	0,4121
12	Oktober 2023	0,5579
13	November 2023	0,4570
14	Desember 2023	0,3821

Hasil peramalan pada Tabel 2 menunjukan bahwa inflasi di Indonesia pada November 2022 sampai dengan Desember 2023 cukup berfluktuatif. Selain itu, inflasi sebesar 0.5579 yang diperkirakan menjadi inflasi terbesar akan terjadi pada 2023 tepatnya pada bulan Oktober, serta peramalan Februari 2023 sebesar 0.203 akan diperkirakan menjadi inflasi terkecil. Berikut Gambar 4 memperlihatkan plot data hasil peramalan.



Gambar 4. Hasil Peramalan

PENUTUP

SIMPULAN

Setelah melakukan analisis dan pembahasan mengenai penerapan dari metode *Backpropagation Neural Network* untuk meramalkan tingkat inflasi di Indonesia, ditemukan bahwa arsitektur terbaik yang digunakan dalam proses pelatihan yaitu menggunakan sebanyak 1 neuron pada lapisan keluarannya, sedangkan untuk lapisan masukan dan lapisan tersembunyi masing-masing sebanyak 12 dan 21 neuron. Sedangkan untuk fungsi aktivasi terbaiknya yaitu terpilih fungsi aktivasi sigmoid biner.

Dalam pembagian data untuk pelatihan dan pengujian masing-masing 50%. Dengan menggunakan arsitektur jaringan 12-21-1, diperoleh *Mean Squared Error* (MSE) pada tahap pelatihan sebesar 0.00067535 serta sebesar 0.0767 untuk tahapan pengujiannya. Berdasarkan tahapan peramalan, inflasi sebesar 0.5579 yang diperkirakan menjadi inflasi terbesar akan terjadi pada 2023 tepatnya pada bulan Oktober, serta peramalan Februari 2023 sebesar 0.203 akan diperkirakan menjadi inflasi terkecil.

SARAN

Bagi penelitian selanjutnya, agar memudahkan dalam penentuan dari parameter terbaiknya, dapat dilakukan proses *Hyperparameter Tuning* agar memudahkan dalam proses pembangunan arsitektur dan mendapatkan arsitektur terbaik. Selain itu, penggunaan data dapat diperbanyak lagi serta dapat menggunakan fungsi aktivasi yang lainnya.

DAFTAR PUSTAKA

- Achmalia, A. F., Walid, W., & Sugiman, S. (2020). Peramalan Penjualan Semen Menggunakan Backpropagation Neural Network Dan Recurrent Neural Network. *UNNES Journal of Mathematics*, 9(1), 6-21.
- Aini, H., Haviluddin, H., Budiman, E., Wati, M., & Puspitasari, N. (2019). Prediksi Produksi Minyak Kelapa Sawit Menggunakan Metode Backpropagation Neural Network. *Sains, Aplikasi, Komputasi dan Teknologi Informasi*, 1(1), 24-33.
- Afrianto, R.B., Tjandrasa, H., & Arieshanti, I. (2013). Prediksi Pergerakan Harga Saham Menggunakan Metode Back Propagation Neural Network. *Jurnal SimanteC*, 3(3), 132-141.
- Arhami, M. dan Nasir, M. (2020). *Data Mining Algoritma dan Pemrograman*. Penerbit Andi, Yogyakarta.
- Badan Pusat Statistik. (2021). Inflasi. <https://www.bps.go.id/subject/3/inflasi.html#subjekViewTab1>. Diakses pada 19 September 2022.
- Budianita, E. dan Prijodiprodo, W. (2013). Penerapan Learning Vector Quantization (LVQ) untuk Klasifikasi Status Gizi Anak. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 7(2), 155-166.
- Chamidah, N. dan Salamah, U. (2012). Pengaruh Normalisasi Data pada Jaringan Saraf Tiruan Backpropagasi Gradient Descent Adaptive Gain (BPGDAG) untuk Klasifikasi. *ITSMART Jurnal Teknologi dan Informasi*, 1(1), 28-33.
- Gema, R. L. & Kartika, D. (2018). Algoritma Propagasi Balik dalam Pencarian Pola Training Terbaik untuk Menentukan Prediksi Produksi Usaha Songket Silungkang dengan menggunakan Matlab. *Komik*, 2(1), 58-64.
- Heaton, J. The Number of Hidden Layers. 2017.
- Hidayat, R. & Suprpto. (2012). Meminimalisasi Nilai Error Peramalan dengan Algoritma Extreme Learning Machine. *Jurnal Optimasi Sistem Industri UNAND*, 11(1), 187-192.
- Montgomery, D.C., Jennings, C.L., and Kulahci, M. (2015). *Introduction to Time Series Analysis and Forecasting*. 2nd Edition. John Wiley & Sons Inc., New Jersey.
- Nurmila, N., Sugiharto, A. & Sarwoko, E. A. (2010). Algoritma Back Propagation Neural Network untuk Pengenalan Pola Karakter Huruf Jawa. *Jurnal Masyarakat Informatika*. 1(1), 2086-4930.
- Purnawansyah, P., Haviluddin, H., Setyadi, H. J., Wong, K., & Alfred, R. (2019). An Inflation Rate Prediction Based on Backpropagation Neural Network Algorithm. *International Journal of Artificial Intelligence Research*, 3(2), 92-98.
- Ramadhona, G., Setiawan, B.D., & Bachtiar, F.A. (2018). Prediksi Produktivitas Padi Menggunakan Jaringan Saraf Tiruan Backpropagation. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 2(12), 6049-6057.
- Susanti, L.A.D., Fariza, A., & Setiawardhana, S. (2011). Peramalan Harga Saham Menggunakan Recurrent Neural Network Dengan Algoritma Backpropagation Through Time (BPPT) (Tugas Akhir). Jurusan Teknik Informatika FT ITS, Surabaya.
- Susilokarti, D., Arif, S. S., Susanto, S., & Sutiarto, L. (2015). Studi Komparasi Prediksi Curah Hujan Metode Fast Fourier Transformation

(FFT), Autoregressive Integrated Moving Average (ARIMA) dan Artificial Neural Network (ANN). *Agritech*, 3(2), 241-247.

Sutawijaya, A. (2012). Pengaruh Faktor-Faktor Ekonomi Terhadap Inflasi di Indonesia. *Jurnal Organisasi dan Manajemen*, 8(2), 85-101.

Thakur, G.S.M., Bhattacharyya, R., and Mondal, S.S. (2016). Artificial Neural Network Based Model for Forecasting of Inflation in India. *Fuzzy Information and Engineering*, 8(1), 87-100.