

# Prediksi Tingkat Inflasi Bulanan Indonesia Menggunakan Metode Jaringan Saraf Tiruan

**B Hauriza<sup>1\*</sup>, Muladi<sup>2</sup>, I M Wirawan<sup>3</sup>**

Program Studi Teknik Informatika, Universitas Negeri Malang<sup>123</sup>

Jalan Semarang No.5, Malang, 65145, Indonesia<sup>123</sup>

bintang.hauriza.1605356@students.um.ac.id<sup>1\*</sup>, muladi@um.ac.id<sup>2</sup>, made.wirawan.ft@um.ac.id<sup>3</sup>

diterima: 17 Mei 2021

direvisi: 20 Agustus 2021

dipublikasi: 1 September 2021

## Abstrak

Bank Indonesia mendefinisikan inflasi merupakan meningkatnya harga-harga secara umum dan terus-menerus. Kenaikan harga barang dan jasa dapat disebut inflasi apabila kenaikan tersebut meluas atau mempengaruhi kenaikan harga lainnya. Naiknya harga barang dan jasa tersebut dapat menyebabkan turunnya nilai uang. Dengan ini, inflasi dapat menurunkan nilai uang terhadap nilai barang dan jasa secara umum. Jika inflasi yang terjadi dapat dikendalikan dengan baik, tingkat inflasi tersebut dapat memberikan dampak positif terhadap pertumbuhan ekonomi. Tujuan dari penelitian ini yaitu dapat memprediksi tingkat inflasi agar inflasi dapat dikontrol tiap bulannya dan dapat memberikan dampak yang positif. Penelitian ini menggunakan metode jaringan syaraf tiruan yang sesuai digunakan pada data *time series* dengan data training. Data yang digunakan adalah data inflasi bulanan kelompok pengeluaran dari bulan Desember 2011 sampai Desember Januari 2020 diambil dari Badan Pusat Statistik. Penelitian ini diharapkan dapat membantu untuk memutuskan tindakan yang tepat berdasarkan hasil prediksi. Pengujian menggunakan beberapa model diperoleh hasil terbaik dari model dengan konfigurasi 7-15-1 dengan *learning rate* 0,01 yang menghasilkan MSE sebesar 0,026. Hasil ini menunjukkan bahwa jaringan syaraf tiruan dapat digunakan untuk prediksi inflasi dengan akurasi yang tinggi.

**Kata kunci:** prediksi; inflasi; jaringan saraf tiruan; *time series*

## Abstract

Bank Indonesia defines inflation as increasing prices in general and continuously. An increase in the price of goods and services can be called inflation if the increase is widespread or affects other price increases. The increase in the price of goods and services can cause a decrease in the value of money. With this, inflation can reduce the value of money against the value of goods and services in general. If the inflation that occurs can be controlled properly, the inflation rate can have a positive impact on economic growth. The purpose of this study is to predict the inflation rate so that inflation can be controlled every month and can have a positive impact. This study uses an artificial neural network method that is suitable for use on time series data with training data. The data used is monthly inflation data for expenditure groups from December 2011 to December January 2020 taken from the Central Statistics Agency. This research is expected to help to decide the right action based on the prediction result. Testing using several models obtained the best results from the model with a configuration of 7-15-1 with a learning rate of 0.01 which resulted in an MSE of 0.026. These results indicate that the artificial neural network can be used for inflation prediction with high accuracy.

**Keywords:** prediction; inflation; artificial neural network; *time series*

## 1. Pendahuluan

Pertumbuhan ekonomi menunjukkan peningkatan dalam produksi barang maupun jasa dalam suatu perekonomian [1]. Salah satu cara untuk melihat tingkat perekonomian yaitu melalui inflasi. Bank Indonesia mendefinisikan inflasi yaitu meningkatnya harga-harga secara umum dan terus menerus [2]. Kenaikan harga barang dan jasa dapat disebut inflasi jika kenaikan tersebut meluas atau mempengaruhi kenaikan harga barang lainnya. Dengan

ini, inflasi dapat menurunkan nilai uang terhadap nilai barang dan jasa secara umum. Inflasi penting untuk dijaga kestabilannya karena laju inflasi mempengaruhi pertumbuhan ekonomi yang berdampak juga pada peningkatan kesejahteraan masyarakat.

Sedangkan turunnya harga barang dan jasa disebut deflasi. Inflasi dipengaruhi oleh faktor-faktor *fundamental* antara lain interaksi antara permintaan dan penawaran terhadap barang dan jasa, lingkungan eksternal seperti nilai tukar mata uang, harga komoditi internasional [2]. Selain faktor *fundamental*, faktor *non-fundamental* antara lain yaitu inflasi makanan yang berlebihan, yang dipengaruhi oleh bahan makanannya sendiri seperti hasil panen yang menurun, gangguan dari bencana alam (banjir, angin topan, longsor, dll), dan faktor peraturan pemerintah yang umumnya dipengaruhi oleh pengumuman harga yang dibuat pemerintah seperti harga subsidi BBM, listrik, transportasi umum, dan lainnya. Dengan dilakukannya pengendalian inflasi akan mencegah kenaikan laju inflasi yang terlalu tinggi atau penurunan (deflasi) yang terlalu rendah dan menghindari terjadinya dampak negatif pada kondisi ekonomi masyarakat Indonesia.

Penelitian ini ditujukan agar dapat memprediksi tingkat inflasi kedepannya dan membantu untuk menentukan tindakan yang tepat bagi masyarakat berdasarkan hasil prediksinya. Bagi produsen, inflasi dapat bernilai positif jika keuntungan yang diperoleh lebih tinggi dibandingkan dengan biaya produksinya. Selain produsen, inflasi juga dapat menguntungkan orang yang akan meminjam uang dari bank karena pada saat pembayaran utang nilai uang lebih rendah dibandingkan saat meminjam. Tetapi, hal ini yang akan merugikan pihak yang meminjamkan karena akan mengalami kerugian nilai uang pengembalian lebih rendah dibandingkan saat peminjaman.

Penelitian ini akan menggunakan metode Jaringan Saraf Tiruan untuk memprediksi tingkat inflasi bulan berikutnya. Data yang digunakan untuk penelitian ini yaitu data inflasi bulanan di Indonesia dari bulan Desember 2011 sampai Desember 2019 (97 bulan) yang dikeluarkan oleh Badan Pusat Statistik. Terdapat 7 variabel yang digunakan dalam memprediksi inflasi pada penelitian ini, yaitu 1) Bahan Makanan, 2) Makanan Jadi, Minuman, Rokok, dan Tembakau, 3) Perumahan, Air, Listrik, Gas, dan Bahan Bakar, 4) Sandang, 5) Kesehatan, 6) Pendidikan, 7) Transpor dan Komunikasi dan Jasa Keuangan, dan 8) Inflasi Umum. Penelitian ini menggunakan riwayat inflasi umum dari bulan-bulan sebelumnya untuk memprediksi inflasi bulan selanjutnya.

## 2. Kajian Pustaka

### 2.1. Penelitian yang Relevan

Terdapat beberapa yang sudah dilakukan sebelumnya dengan pembahasan prediksi inflasi. Pada penelitian sebelumnya yang dilakukan oleh (Wahyuddin, 2019) menggunakan Model ARIMA dan ~~Artificial Neural Network~~ *Neural Network-Feed Forward* untuk memprediksi inflasi dan membandingkan hasil dari kedua metode tersebut. Dataset yang digunakan yaitu data inflasi perbulan dari Januari 2010 sampai Desember 2018 yang berasal dari Badan Pusat Statistik dan Bank Indonesia. Dataset berupa 7 atribut yang mempengaruhi laju inflasi yaitu antara lain a) Suku Bunga, b) Tingkat Pengangguran, c) Produk Domestik Regional Bruto, d) Produk Domestik Bruto Indonesia, e) Upah Minimum Regional, f) Kurs Jual, dan g) Kurs Beli. Ketujuh atribut tersebut juga ~~digunakan sebagai~~ *digunakan sebagai* masukan~~nya~~ dan akan memberikan output *prediksi* inflasi umum.

Hasil prediksi ARIMA dengan menggunakan model (2,1,0), (2,0,0) [12] menunjukkan nilai MAPE (*Mean Absolute Percentage Error*) sebesar 9,12%, MAD (*Mean Absolute Deviation*) sebesar 0,10, MSE (*Mean Squared Error*) sebesar 0,01 dan RMSE (*Root Mean Square Deviation*) sebesar 0,11.

Penelitian lain yang dilakukan oleh (Amrin, 2016) yaitu Analisa Komparasi *Neural Network* *Neural Network Backpropagation Multiple Linear Regression* untuk Peramalan Tingkat Inflasi. Data yang digunakan dalam penelitian yaitu data inflasi bulanan Indonesia menurun kelompok pengeluaran tahun 2006-2015 dari Badan Pusat Statistik dimana 80% dari data sebagai data latih dan 20% sebagai data uji. Arsitektur jaringan yang digunakan dalam penelitian ini yaitu 7 unit *input*, 15 *hidden unit*, dan 1 *output* dengan nilai MSE 0,0069 dan RMSE sebesar 0,083. 7 *input* yang digunakan dalam penelitian ini yaitu: 1) Inflasi Makanan, 2) Inflasi Makanan Jadi, Minuman, Rokok dan Tembakau, 3) Inflasi Perumahan, Air, Listrik, Gas dan Bahan Bakar, 4) Inflasi Sandang, 5) Inflasi Kesehatan, 6) Inflasi Pendidikan, Rekreasi, dan Olaharaga, 7) Inflasi Transportasi, Komunikasi, dan Jasa Keuangan. Sedangkan *output* yang dihasilkan yaitu Inflasi umum.

## 2.2. Peramalan (Forecasting)

Peramalan merupakan suatu teknik untuk memperkirakan suatu nilai pada masa yang akan datang dengan memperhatikan data masa lalu maupun data saat ini [3]. Peramalan ini bertujuan untuk mengurangi kemungkinan ketidakpastian sehingga diperoleh perkiraan yang mendekati dengan keadaan sebenarnya. Untuk menentukan apakah suatu peristiwa atau kuantitas dapat diprediksi yaitu tergantung pada beberapa faktor antara lain: 1) seberapa baik pemahaman tentang faktor-faktor yang berkaitan, 2) berapa banyak data yang tersedia, dan 3) apakah ramalan akan mempengaruhi hal yang akan diramalkan.

Tujuan dari peramalan sendiri yaitu menghasilkan sesuatu yang di inginkan untuk terjadi. Peramalan menjadi bagian penting dalam kegiatan manajemen pengambilan keputusan. Saat ini, organisasi modern membutuhkan ramalan jangka pendek, jangka menengah, dan jangka panjang tergantung pada spesifikasi aplikasi.

## 2.3. Machine Learning

*Machine Learning* (ML) atau pembelajaran mesin merupakan pendekatan dalam *Artificial Intelligent* (AI) yang banyak digunakan untuk menggantikan atau menirukan perilaku manusia untuk menyelesaikan masalah atau melakukan otomatisasi [4]. Sistem yang dapat dihasilkan oleh *Machine Learning* antara lain seperti mesin pencari, *platform* rekomendasi, dan perangkat lunak pengenalan suara dan gambar. Teknik *Machine Learning* memanfaatkan *platform* komputasi yang kuat dan ketersediaan kumpulan data dengan ukuran yang sangat besar. *Machine Learning* memiliki ciri khas yaitu terdapat proses *training*.

### 2.3.1. Jaringan Saraf Tiruan

*Neural Network* atau jaringan saraf tiruan adalah salah satu representasi buatan yang selalu mencoba mensimulasikan proses pembelajaran pada otak manusia. Jaringan saraf tiruan terdiri atas lapisan *input* dan lapisan *output*. Tiap lapisan memiliki beberapa unit *neuron* yang mempunyai sebuah fungsi aktivasi yang menentukan dari unit keluar. Untuk menambah performa dari jaringan saraf tiruan tersebut, dapat ditambahkan lapisan tersembunyi (*Hidden Layer*). Jaringan saraf tiruan dapat dilatih menggunakan data latih (*data training*). Semakin banyak *data training*, maka performa kerja dari jaringan saraf tiruan akan semakin bagus.

### 2.3.2. Supervised Learning

*Supervised learning* atau pembelajaran terbimbing digunakan untuk menggambarkan tugas dari prediksi karena tujuannya adalah untuk meramalkan atau mengklasifikasikan hasil tertentu [5]. *Supervised Learning* telah digunakan pada struktur data yang besar termasuk

prediktor demografis, klinis, dan sosial untuk mengembangkan nilai risiko memprediksi keadaan darurat dan berbagai gangguan mental. *Supervised Learning* untuk memprediksi hasil berdasarkan kategori disebut sebagai klasifikasi dalam literatur *Machine Learning*. Sedangkan prediksi hasil yang berkelanjutan disebut regresi [5]. Salah satu pendekatan yang paling populer untuk *Supervised Learning* adalah metode *Decision Tree*.


### 2.3.3. Backpropagation

*Machine Learning* mempelajari cara untuk meningkatkan kinerja dalam metode jaringan saraf tiruan. Dimulai dengan mendefinisikan arsitektur jaringan saraf, yang terdiri dari *neuron-neuron* yang saling terhubung. Sebagai contoh, beberapa kasus sering menggunakan *neuron* dengan jumlah lapisan yang banyak, karena arsitektur ini telah terbukti efektif untuk banyak kasus [6]. Kemudian, mendefinisikan kesalahan yang mengkuantifikan seberapa buruk jaringan ini setelah menghasilkan tujuan atau *output* yang diinginkan yang kemudian jaringan akan mencari algoritma lain untuk memperkecil kesalahan tersebut.

### 2.3.4. Fungsi Aktivasi

Fungsi aktivasi yang optimal pada jaringan saraf tiruan merupakan hal yang penting karena berhubungan langsung dengan tingkat keberhasilan yang diperoleh [7]. Fungsi aktivasi dilatih berdasarkan dataset *training* yang terdiri dari jumlah masukan setiap *neuron* pada *hidden layer* dan *output* yang diinginkan. Dalam jaringan saraf tiruan, fungsi aktivasi yang digunakan mengikuti beberapa kriteria yaitu antara lain: kontinu, dapat diturunkan dan fungsi nya tidak turunkan. Fungsi aktivasi terdapat 2 jenis yaitu linear dan non-linear.

Fungsi linear mempunyai nilai keluaran yang sama dengan nilai masukannya [7]. Rumus fungsi ini dapat dituliskan sebagai:  $x = y$ . Terdapat beberapa fungsi aktivasi non-linear salah satu nya yaitu *Rectified Linear Unit* (ReLU). Rumus fungsi ReLU dituliskan sebagai:  $R(z) = \max(0, z)$  dengan grafik pada Gambar 1.



Gambar 1. Grafik ReLU (*Rectified Linear Unit*)

## 2.4. Preprocessing

*Preprocessing* digunakan untuk mengelola data yang digunakan sebagai evaluasi yang diproses menggunakan metode tertentu. Tahapan ini berguna untuk memperbaiki kualitas data, seperti membersihkan data dari isi nilai yang hilang yang dapat dikarenakan malfungsi dari alat pengumpul data, tidak konsisten dalam merekam data dan ada sebagai data terhapus, tidak menyimpan riwayat penyimpanan atau perubahan data. Selain itu, juga memperbaiki data yang seharusnya bersifat unik, tetapi terdapat duplikat seperti data *username*.

### 2.4.1. Normalisasi

Normalisasi data adalah salah satu pendekatan *preprocessing* yang datanya diskalakan atau dirubah untuk membuat kontribusi yang sama dari masing-masing fitur [8]. Pentingnya normalisasi data yaitu untuk meningkatkan kualitas data dan kemudian mempermudah kinerja algoritma *Machine Learning*. Macam-macam metode dikategorikan berdasarkan

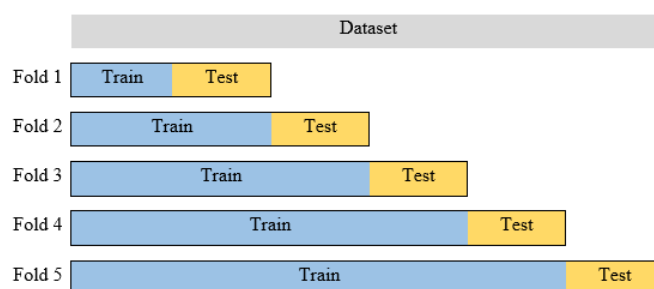
bagaimana karakter statistik tertentu dari dataset yang digunakan untuk normalisasi data. Pada penelitian ini menggunakan metode *Minimum-Maximum Normalization*. Metode ini memperbaiki data yang tidak normal ke standar yang lebih rendah dan batas atas secara linear. Nilai data biasanya dalam rentang 0 hingga 1 atau -1 hingga 1.

## 2.5. Evaluasi

Evaluasi adalah suatu alat atau prosedur yang digunakan untuk mengetahui dan mengukur sesuatu dalam suasana dengan cara dan aturan-aturan yang sudah ditentukan [9]. *Cross Validation* merupakan salah satu metode untuk melakukan evaluasi. Selain itu, terdapat juga *Mean Absolute Percentage Error*.

### 2.5.1 Forward-Chaining Cross Validation

*Cross Validation* adalah salah satu metode yang paling banyak digunakan untuk menilai generalisasi algoritma dalam klasifikasi dan regresi, digunakan pada penelitian aktif yang sedang berlangsung [10]. *Cross Validation* membagi dataset menjadi dua bagian dengan satu bagian menjadi data *training*, dan satu bagian lainnya menjadi data *testing* [11]. Untuk dataset *time series* menggunakan *Forward-Chaining Cross Validation* dengan proses seperti berikut.



Gambar 2. Cara kerja *Forward-Chaining Cross Validation*

### 2.5.2 Mean Squarred Error

*Mean Squarred of Error* (MSE) memiliki peran penting untuk menilai seberapa akurat sebuah algoritma khususnya untuk data *timeseries* yang nilainya tidak selalu sama setiap waktu, seperti indeks kualitas udara. MSE merupakan rata-rata selisih kuadrat antara nilai yang diramalkan dan diamati [12]. Jika nilai MSE semakin mendekati 0, maka semakin baik yang artinya hasil prediksi yang didapatkan mendekati data aktual nya. Rumus MSE dapat digambarkan sebagai berikut:

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - Y'_t)^2 \quad (1)$$

Keterangan:

MSE = *Mean Absolute Percentage of Error*


$Y_t$  = Nilai data *timeseries* pada periode t

$Y'_t$  = Nilai prediksi dari  $Y_t$

## 3. Metode Penelitian

### 3.1 Desain Penelitian

Desain penelitian Prediksi Tingkat Inflasi Bulanan Indonesia Meggunakan Metode Jaringan Saraf Tiruan ini ditunjukkan pada Gambar 3.



Gambar 3. Desain Penelitian

### 3.2 Identifikasi Masalah

Penelitian yang dilakukan adalah untuk mengetahui konfigurasi model jaringan saraf tiruan untuk melakukan prediksi *time-series* dan memberikan prediksi nilai inflasi Indonesia di bulan berikutnya.

### 3.3 Studi Literatur

Pada proses ini dilakukan studi literatur yang diperoleh dari berbagai referensi jurnal, prosiding, buku, skripsi dan penelitian sebelumnya yang terkait dengan prediksi, jaringan saraf tiruan dan inflasi untuk mendapatkan informasi yang mendukung penelitian. Metode prediksi yang digunakan dalam penelitian data *time-series* ini adalah jaringan saraf tiruan.


### 3.4 Data Penelitian

Data untuk penelitian ini didapat dari situs web Badan Pusat Statistik yang memberikan informasi seputar statistik dibidang sosial dan kependudukan, ekonomi dan perdagangan, dan pertanian dan pertambangan. Pada penelitian ini menggunakan dataset inflasi tiap bulannya dari Desember 2011 sampai Desember 2019. Dari website Badan Pusat Statistik, data inflasi mulai Januari 2020 terdapat perubahan jumlah variabel sehingga data pada tahun 2020 tidak disatukan dalam satu dataset dalam penelitian ini.

Dataset berjumlah 97 *instances* yang terdiri dari 8 atribut yaitu Bahan Makanan (BM); *Date*; Makanan, Minuman, Rokok dan Tembakau (MMRT); Perumahan, Air, Listrik, Gas, dan Bahan Bakar (PALGGB); Sandangan; Kesehatan; Pariwisata, Rekreasi dan Olahraga (PRO), Transportasi, Komunikasi dan Jasa Keuangan (TKJK); dan inflasi umum. Atribut *date* merupakan tahun dan bulan inflasi.

### 3.5 Jaringan Saraf Tiruan

*Neural Network* atau jaringan saraf tiruan adalah salah satu representasi buatan yang mensimulasikan proses pembelajaran pada sistem otak manusia. Jaringan saraf tiruan terdiri atas lapisan input dan lapisan output. Tiap lapisan memiliki beberapa unit neuron yang mempunyai sebuah fungsi aktivasi dan akan menentukan dari unit keluar. Lapisan tersembunyi (*hidden layer*) ditambahkan pada konfigurasi jaringan syaraf tiruan untuk meningkatkan kinerjanya. Jaringan saraf tiruan dapat dilatih menggunakan data latih (*data training*). Jumlah dan variasi data latih akan mempengaruhi hasil pembelajaran yang akan menentukan kemampuan jaringan syaraf memproses data input. Gambar 4 menunjukkan konfigurasi umum dari jaringan saraf tiruan dengan konfigurasi 1-2-1.



Gambar 4. Topologi Jaringan Saraf Tiruan 1-2-1

### 3.6 Model Prediksi

Pada penelitian prediksi tingkat inflasi bulanan Indonesia menggunakan metode jaringan saraf tiruan ini terdapat beberapa macam konfigurasi neuron untuk mencari konfigurasi yang terbaik namun tetap dalam arsitektur yang sama yaitu 1 lapis input, 1 lapis hidden, dan 1 lapis output. Penelitian ini menggunakan pelatihan *backpropagation* dengan 4 konfigurasi input yaitu 5, 6, 7 dan 8. Penentuan konfigurasi input ditentukan berdasarkan penelitian yang dilakukan oleh (Omar Pahlevi, 2016; Desy Lasterina, 2016). Kemudian terdapat 4 konfigurasi hidden yaitu 5, 10, 15 dan 20, dan yang terakhir 4 konfigurasi *learning rate* yaitu 0,1, 0,2, 0,3 dan 0,4.

Konfigurasi input terdiri dari riwayat inflasi umum disusun berdasarkan urutan historis. Misalnya 5 input berarti menggunakan 5 urutan riwayat inflasi seperti Desember 2011, Januari 2012, Pebruari 2012, Maret 2012, dan April 2012. Outputnya adalah prediksi inflasi untuk bulan berikutnya yaitu Mei 2012. Input untuk konfigurasi 6, 7 dan 8 akan disesuaikan dengan target output yang dikehendaki dan dihitung mundur sesuai jumlah input yang akan digunakan tersebut.

Langkah berikutnya adalah mencari konfigurasi terbaik untuk melakukan prediksi berdasarkan nilai *Mean Absolute Percentage Error* (MAPE) dan kecepatan training menuju kondisi konvergensi. Pada penelitian ini terdapat  $4^3$  atau 64 skenario berdasarkan 4 konfigurasi input, 4 konfigurasi *hidden unit*, dan 4 nilai *learning rate*. Dari hasil pengujian akan dipilih 5 model yang memiliki nilai MAPE terkecil untuk diuji menggunakan validasi silang (*cross validation*) sebanyak 5 *fold* dan data uji selama 2 tahun.

## 4. Hasil dan Pembahasan

### 4.1 Dicky-Fuller Test

*Dicky Fuller Test* mempertimbangkan hipotesa *null* bahwa data *time series* tidak stasioner. Hipotesa berbeda tergantung pada jenis tes yang digunakan, tetapi biasanya *stationary* atau *trend-stationary*. *Dicky Fuller Test* memberikan nilai *p* yang berfungsi untuk menentukan apakah data tersebut stasioner atau tidak. Jika nilai *p* kurang dari 0,05 saat pengujian, maka hipotesa tersebut ditolak dan data dianggap stasioner.


Pengujian *Dicky Fuller* pada dataset inflasi di Indonesia diperoleh hasil nilai *p* kurang dari 0,05 (0,0000000000001920) yang artinya dataset inflasi tersebut adalah stasioner.

### 4.2 Autocorrelation Function

*Autocorrelation Function* digunakan dalam menganalisis data *time series*. Fungsi ini digunakan untuk menghitung hubungan antara sebuah seri dan pergeseran waktunya. Fungsi ini juga digunakan untuk mengidentifikasi musiman dan tren [13]. Informasi ini selanjutnya akan digunakan untuk mengidentifikasi jeda waktu dan membatasi ukuran waktu yang digunakan sebagai input pada model prediksi inflasi.



Gambar 5 menunjukkan nilai *autocolleration* pada dataset inflasi. Fluktuasi nilai terjadi secara periodik setiap 5-6 kali dan ada kecenderungan peningkatan nilai dalam tiap periode. Periode 15-20 lebih tinggi daripada periode sebelumnya yakni periode 10-15. Demikian juga periode 10-15 lebih tinggi daripada periode 5-10.



Gambar 5. Plot dataset inflasi

#### 4.3 Simple Moving Average

*Moving Average* merupakan indikator yang berfungsi untuk menghaluskan pergerakan nilai dengan cara menyaring fluktuasi nilai yang sifatnya acak. *Moving Average* dihitung berdasarkan nilai rata-rata pergerakan nilai dalam periode tertentu misalnya 3 bulan dan 6 bulan. *Simple Moving Average* dihitung dengan rumus yaitu nilai rata-rata pergerakan nilai dalam periode tertentu menggunakan rumus dibawah. Gambar 6 menunjukkan nilai moving average inflasi Indonesia dengan periode tertentu.

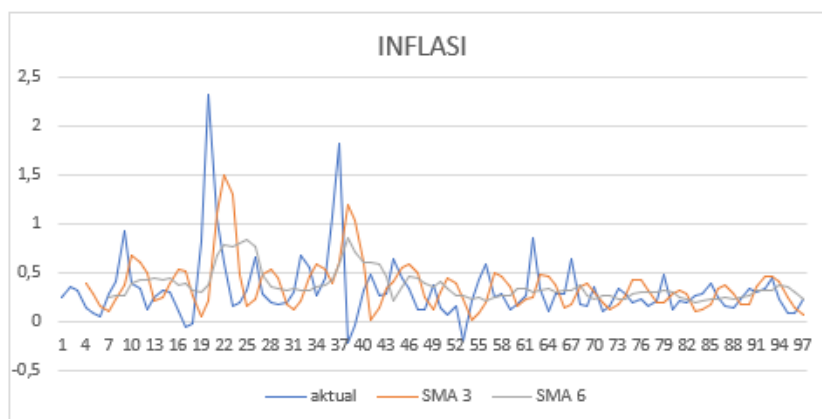
$$\bar{P}_n = \frac{P_1 + P_2 + \dots + P_n}{n} \quad (2)$$

Keterangan:

$\bar{P}_n$  = Nilai rata-rata inflasi per n bulan

$P_n$  = Nilai inflasi per bulan

n = jumlah bulan



Gambar 6. Moving Average Inflasi

#### 4.4 Hidden Unit


Jumlah *hidden unit* pada model *Neural Network* juga mempengaruhi hasil perhitungan pada setiap neuron sehingga mempengaruhi hasil prediksinya. Parameter *hidden unit* yang digunakan dalam penelitian ini yaitu 5, 10, 15, dan 20.



Pada Tabel 1, proses pelatihan menggunakan *learning rate* 0,0001 pada semua jumlah *hidden unit* nilai MSE nya paling tinggi dibandingkan dengan menggunakan *learning rate* lainnya pada semua jumlah *hidden unit*. Pada jumlah *hidden unit* 5 dengan *learning rate* 0,0001 memiliki nilai MSE *train* sebesar 12,87. Kemudian pada jumlah *hidden unit* 10 nilai MSE *train* nya menurun menjadi 4,48. Sehingga, dari tabel 1 dapat disimpulkan bahwa nilai MSE *train* semakin menurun dengan bertambahnya jumlah *hidden unit*.

Tabel 1. Perbandingan nilai MAPE terhadap parameter *hidden unit*

<i>Hidden Unit</i>	<i>Learning Rate</i>	MSE (train)	MSE (test)	<i>Time</i>
5	0,0001	12,87	0,14855	0,416225
	0,001	1,06	0,169525	0,38395
	0,005	1,06	0,171775	0,4154
	0,01	1,62	0,309575	0,0355
10	0,0001	4,48	0,414625	0,5296
	0,001	0,5578	0,5403	0,512075
	0,005	1,084275	1,279375	0,4996
	0,01	0,59725	1,387275	0,5006
15	0,0001	1,57155	0,10515	0,518775
	0,001	0,4665	0,195775	0,52875
	0,005	0,69155	0,68465	0,51465
	0,01	0,421475	1,72315	0,5124
20	0,0001	1,901975	0,200325	0,523675
	0,001	0,393025	0,606325	0,520575
	0,005	0,469375	8,9517	0,5284
	0,01	0,355875	2,881225	0,5157



Gambar 7. Perbandingan jumlah *hidden unit*

Pada gambar 7 dapat dilihat ke empat grafik mengalami penurunan bersamaan saat jumlah *hidden unit* 20. Dari tabel 1 terlihat pula nilai MSE hasil pelatihan menggunakan jumlah *hidden unit* 20 memiliki nilai paling rendah dibandingkan dengan nilai MSE yang menggunakan jumlah *hidden unit* lainnya.

Tabel 2. Perbandingan rata rata parameter *hidden unit*.

<i>Hidden</i>	MSE (train)	MSE (test)	<i>Time</i>
5	4,154294	0,199856	0,312769
10	1,67983	0,905394	0,510469
15	0,78777	0,677181	0,518644
20	0,78006	3,159894	0,522096

Pada saat proses pelatihan, semakin tinggi jumlah *hidden unit* nya, semakin rendah nilai MSE nya. Hal ini ditunjukkan oleh Tabel 2, bahwa *hidden unit* 20 mendapatkan nilai MSE *train* terkecil dibandingkan dengan menggunakan jumlah *hidden unit* yang lain. Semakin kecil jumlah *hidden unit* nya, nilai MSE *train* semakin besar. Selain itu, juga membutuhkan waktu yang lebih banyak. Pada tabel 2 dapat dilihat nilai MSE pengujian dengan hasil terbaik terletak pada *hidden unit* 5.

#### 4.5 Learning Rate


*Learning Rate* merupakan parameter penting yang dapat mempengaruhi model melakukan perubahan *weight* pada saat proses pembelajaran. Penggunaan *Learning Rate* ditujukan untuk meningkatkan kinerja pada proses pembelajaran. Pemilihan *learning rate* dilakukan secara acak, tetapi tetap mempertimbangkan agar tidak terlalu rendah ataupun terlalu tinggi. Jika *learning rate* yang dipilih tidak tepat, dapat menyebabkan proses pembelajaran menjadi lambat untuk mencapai titik konvergen.

Tabel 3. Perbandingan nilai rata-rata parameter *learning rate*


Learning Rate	Input	MSE (train)	MSE (test)	Time
0,0001	5	2,51	0,31	0,49
	6	2,5575	0,16333	0,49785
	7	7,29698	0,28958	0,49225
	8	8,4625	0,10633	0,49185
0,001	5	0,6473	0,7337	0,49
	6	0,75078	0,44345	0,49785
	7	0,7939	0,0996	0,4626
	8	0,28505	0,2352	0,494925
0,005	5	0,71	5,23	0,52
	6	0,81663	2,77165	0,4748
	7	0,848	2,86793	0,5138
	8	0,9312	0,21638	0,5215
0,01	5	0,84	1,86	0,52
	6	0,6257	2,22713	0,39558
	7	0,95023	2,00075	0,5113
	8	0,57715	0,21718	0,498

Pada Tabel 3, MSE pada pelatihan yang menggunakan *learning rate* 0,0001 nilainya cukup tinggi dibandingkan dengan nilai MSE lainnya yang menggunakan *learning rate* selain 0,0001. Dari tabel tersebut, dapat dilihat bahwa *learning rate* 0,0001 terlalu rendah untuk model ini sehingga MSE yang didapatkan nilainya tinggi. Tetapi, saat melakukan pengujian menggunakan *learning rate* 0,0001, hasil MSE nya cukup rendah dan cenderung menurun dengan meningkatnya jumlah *input*.

Dapat disimpulkan bahwa *learning rate* 0,0001 terlalu kecil sehingga model sulit untuk mencapai titik konvergen dibandingkan dengan model dengan *learning rate* lebih tinggi. Namun model sudah memiliki akurasi yang cukup baik pada pengujiannya.



Gambar 8. Perbandingan MSE train parameter *learning rate*



Gambar 9. Perbandingan MSE test parameter *learning rate*

Pada Gambar 8 dapat dilihat grafik dengan nilai MSE *train* paling tinggi terdapat pada grafik dengan nilai *learning rate* 0,0001. Nilai MSE *train* terkecil terdapat pada grafik dengan nilai *learning rate* 0,001. Tetapi pada jumlah *input* 6, nilai MSE *train* dengan *learning rate* 0,001 cukup tinggi. Sedangkan pada jumlah *input* 8 paling kecil. Dari Gambar 8 dapat diambil kesimpulan, semakin banyak jumlah *input* nya, nilai MSE nya juga semakin kecil. Sama seperti Gambar 8, pada Gambar 9 juga terlihat semakin banyak jumlah *input* nya, semakin kecil nilai MSE *test* nya. Tetapi pada MSE *train*, grafik dengan nilai tertinggi terdapat pada *learning rate* 0,0001. Sedangkan pada MSE *test*, grafik dengan nilai *learning rate* 0,0001 paling rendah

Tabel 4. Perbandingan rata-rata parameter *learning rate*

Learning Rate	MSE (train)	MSE (test)	Time
0,0001	5,21	0,22	0,50
0,001	0,62	0,38	0,49
0,005	0,83	2,77	0,51
0,01	0,75	1,58	0,48

Pada Tabel 4, MSE pada pelatihan nilainya paling tinggi menggunakan *learning rate* 0,0001 dibandingkan dengan nilai MSE yang menggunakan *learning rate* lainnya, dan nilai MSE terendah saat menggunakan *learning rate* 0,001. Sedangkan saat pengujian, nilai MSE paling tinggi terdapat saat menggunakan *learning rate* 0,005 dan nilai MSE terendah saat menggunakan *learning rate* 0,0001.

#### 4.6 Jumlah Masukan


Pola masukan menggunakan pola *n-series*. Dengan *n* sebagai jumlah masukan yang akan dipelajari oleh *Neural Network*. Maksud dari pola *n-series* ini adalah melakukan prediksi menggunakan *n* data sebelumnya. Contoh, untuk pola 5 series akan dilakukan prediksi inflasi bulan Desember 2019, maka prediksi dilakukan menggunakan riwayat inflasi bulan Juli

2019, Agustus 2019, September 2019, Oktober 2019, dan November 2019. Parameter input pada penelitian ini yaitu 5, 6, 7, dan 8.

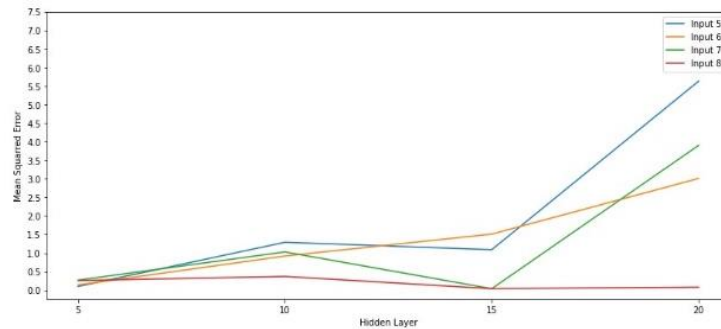
Tabel 5. Perbandingan nilai MSE parameter *input*

<i>Input</i>	<i>Hidden Unit</i>	MSE (train)	MSE (test)	<i>Time</i>
5	5	1,483325	0,1082	0,409
	10	2,138325	1,29325	0,518
	15	0,4841	1,09675	0,52018
	20	0,606475	5,632625	0,5149
6	5	2,53745	0,149925	0,31773
	10	0,83435	0,9211	0,53723
	15	0,8106	1,5179	0,52977
	20	0,5682	3,016625	0,52445
7	5	5,095	0,27165	0,36785
	10	2,734575	1,0354	0,50165
	15	1,570875	0,04895	0,52505
	20	0,48865	3,90185	0,5193
8	5	7,5014	0,26965	0,4135
	10	1,012075	0,371825	0,51415
	15	0,2855	0,045125	0,509125
	20	1,456925	0,088475	0,5374

Pada Tabel 5, dapat dilihat input 5 dan 6 mendapatkan hasil MSE terendah dengan *hidden unit* 5. Sedangkan untuk input 7 dan 8, hasil MSE terendah menggunakan *hidden unit* 15. Dari Tabel 5, dapat diambil kesimpulan bahwa untuk input yang jumlahnya sedikit, cukup menggunakan jumlah *hidden unit* 5. Terbukti pada tabel, semakin banyak jumlah *hidden unit* nya (pada input 5 dan 6), semakin tinggi nilai MSE-nya. Selain itu, terdapat pula keunikan yang dapat dilihat pada Tabel 5, semakin banyak jumlah inputnya, nilai MSE train semakin tinggi. Sedangkan nilai MSE semakin rendah seiring dengan meningkatnya jumlah input.



Gambar 10. Perbandingan MSE train paramtere *input*



Gambar 11. Perbandingan MSE test parameter *input*

Pada Gambar 10 dapat dilihat grafik nilai MSE *train* berdasarkan jumlah *input*. Nilai MSE tertinggi terdapat pada jumlah *input* 8 dengan jumlah *hidden unit* 5. Sedangkan nilai MSE terendah terdapat pada jumlah *input* 7 dengan jumlah *hidden unit* nya 20. Pada Gambar 11 dapat dilihat grafik nilai MSE *test* berdasarkan jumlah *input* nya. Nilai MSE tertinggi terdapat pada jumlah *input* 5 dengan jumlah *hidden unit* 20. Sedangkan nilai MSE terendah terdapat pada jumlah *input* 5 dengan jumlah *hidden unit* 5.

Tabel 6. Perbandingan rata-rata parameter *input*

<i>Input</i>	MSE ( <i>train</i> )	MSE ( <i>test</i> )	<i>Time</i>
5	1,17805625	2,032706	0,3826438
6	1,18765	1,401388	0,4141688
7	2,472275	1,314463	0,3761
8	2,563975	0,193769	0,3534125

Pada Tabel 6, dapat dilihat pada MSE *train* nilainya semakin tinggi seiring dengan jumlah *input* yang semakin banyak. Tetapi, pada MSE *test*, nilainya semakin rendah seiring dengan jumlah *input* nya yang semakin banyak. Pada Tabel 7, nilai MSE terkecil terdapat pada jumlah *input* 7 jika dilihat pada MSE hasil testing. Sedangkan nilai MSE tertinggi terdapat pada jumlah *input* 8.

#### 4.7 Forward-Chaining Cross Validation

Pada penelitian ini terdapat total 64 model yang semuanya telah dilakukan pengujian. Pemilihan skenario 4 terbaik dilihat dari nilai MSE *test* terendah dari 4 parameter *input*. Setiap model pada Tabel 8 dilakukan validasi menggunakan *cross validation* dengan 5 *fold*.

Tabel 7. Model terbaik

Model	<i>Input</i>	<i>Hidden</i>	Learning Rate	MSE ( <i>train</i> )	MSE ( <i>test</i> )	<i>Time</i>
1	5	5	0,0001	2,98	0,0456	0,413
2	6	5	0,005	0,7698	0,0417	0,4154
3	7	15	0,001	0,7135	0,0293	0,517
4	8	15	0,005	1,12	0,0339	0,4937

Tabel 8. Cross Validation (*train*)

		Model			
		1	2	3	4
<i>Fold</i>	1	3,603	1,367	0,767	0,028
	2	3,364	1,067	0,900	0,011
	3	3,581	1,203	0,975	0,007

	4	3,370	0,951	0,864	0,006
	5	3,072	0,802	0,737	0,004
Rata-rata		3,398	1,078	0,845	0,0112


Tabel 9. *Cross Validation (test)*

		Model			
		1	2	3	4
<i>Fold</i>	1	0,156	0,268	0,271	0,732
	2	0,370	0,334	0,350	0,017
	3	0,085	0,048	0,086	0,020
	4	0,049	0,038	0,030	0,008
	5	0,042	0,048	0,028	0,008
Rata-rata		0,702	0,1472	0,153	0,157

Tabel 8 merupakan hasil *cross validation* dengan data latih menggunakan 5 *fold*, sedangkan Tabel 9 dengan data uji. Dari Tabel 8 dapat dilihat nilai MSE paling rendah terdapat pada model 4 dengan nilai MSE 0,0112. Sedangkan pada Tabel 9 nilai MSE terendah terdapat pada model 3 dengan nilai MSE 0,153. Pada Tabel 8, tiap *fold* pada model 4 nilai nya semakin kecil (tidak stabil). Sedangkan pada model 3, nilai MSE nya cenderung stabil pada setiap *fold*. Jadi, untuk prediksi menggunakan model 3 dengan konfigurasi jumlah input 7, jumlah *hidden unit* 15, dan *learning rate* 0,001

#### 4.8 Prediksi


Prediksi dilakukan menggunakan model terbaik yang ditentukan dari pengujian menggunakan *cross validation* sebagaimana gambar 12. Dari hasil pengujian *cross validation*, model terbaik terdapat pada model ke 3 dengan konfigurasi jumlah input 7, jumlah *hidden unit* 15, dan *learning rate* 0,001.



Gambar 12. Arsitektur Jaringan Saraf Tiruan 7-15-1

Tabel 10. Model terbaik dengan MSE terendah

<i>Input</i>	<i>Hidden Unit</i>	<i>Learning Rate</i>	<b>MSE</b>
7	15	0,001	0,026191302



Gambar 13. Prediksi inflasi antara Januari 2019 - Desember 2019

Prediksi pada gambar 13 menggunakan model 3 dengan konfigurasi input 7, *hidden unit* 15 dan *learning rate* 0,001 mendapatkan hasil MSE yaitu 0,026191302. Model ini memiliki tingkat akurasi yang cukup bagus untuk memprediksi tingkat inflasi Indonesia sehingga mendapatkan nilai MSE yang cukup rendah.

## 5. Kesimpulan

Jaringan saraf tiruan dapat digunakan untuk memprediksi tingkat inflasi Indonesia dengan nilai MSE yang cukup rendah yaitu 0,026191302. Untuk penentuan konfigurasi parameter dilakukan dengan cara acak karena untuk model *Neural Network* tidak ada patokan secara umum nya. Sehingga model dibuat berdasarkan dataset yang digunakan. Pada penelitian ini dilakukan beberapa model untuk mengetahui model dengan konfigurasi yang mana yang terbaik untuk prediksi. Selain konfigurasi *input*, *hidden unit* dan *learning rate*, kinerja model juga bergantung pada nilai *weight* dan *bias*. Nilai *learning rate* yang digunakan pada model mempengaruhi seberapa efektif model dalam melakukan pelatihan. Jika nilai *learning rate* terlalu kecil, model akan membutuhkan waktu yang lebih lama untuk melakukan pelatihan. Sedangkan jika nilai *learning rate* terlalu besar, dapat memperburuk performa model karena nilai *error* yang terlalu besar. Pada penelitian prediksi tingkat inflasi ini didapatkan model terbaik nya dengan konfigurasi *input* 7, *hidden unit* 15 dan *learning rate* 0,001. Model diuji menggunakan *cross validation* dengan hasil yang cukup baik dan stabil di setiap *fold* nya.

## Daftar Pustaka

- [1] I. Nuraini, 'Kualitas Pertumbuhan Ekonomi Daerah Kabupaten/Kota Di Jawa Timur', p. 15, 2017.
- [2] I. F. Lubis, 'Analisis Hubungan Antara Inflasi Dan Pertumbuhan Ekonomi: Kasus Indonesia', p. 12.
- [3] T. N. R. Utami and A. Rusgiyono, 'Prediksi Inflasi Beberapa Kota Di Jawa Tengah Tahun 2014 Menggunakan Metode Vector Autoregressive (VAR)', vol. 4, no. 4, p. 10, 2015.
- [4] A. Ahmad, 'Mengenal Artificial Intelligence, Machine Learning, Neural Network, dan Deep Learning', p. 5, 2017.
- [5] T. Jiang, J. L. Gradus, and A. J. Rosellini, 'Supervised Machine Learning: A Brief Primer', *Behav. Ther.*, vol. 51, no. 5, pp. 675–687, Sep. 2020, doi: 10.1016/j.beth.2020.05.002.
- [6] T. P. Lillicrap, A. Santoro, L. Marris, C. J. Akerman, and G. Hinton, 'Backpropagation and the brain', *Nat. Rev. Neurosci.*, vol. 21, no. 6, pp. 335–346, Jun. 2020, doi: 10.1038/s41583-020-0277-3.



- [7] E. Siregar, 'Analisis Metode Backpropagation Dengan Fungsi Aktivasi Sigmoid Bipolar Dan Fungsi Linear Dalam Prediksi Pertumbuhan Penduduk', p. 76.
- [8] D. Singh and B. Singh, 'Investigating the impact of data normalization on classification performance', *Appl. Soft Comput.*, p. 105524, May 2019, doi: 10.1016/j.asoc.2019.105524.
- [9] A. D. Muryadi, 'Model Evaluasi Program Dalam Penelitian Evaluasi', p. 16, 2017.
- [10] C. Bergmeir, R. J. Hyndman, and B. Koo, 'A note on the validity of cross-validation for evaluating autoregressive time series prediction', *Comput. Stat. Data Anal.*, vol. 120, pp. 70–83, Apr. 2018, doi: 10.1016/j.csda.2017.11.003.
- [11] E. Rilvani, A. B. Trisnawan, and P. P. Santoso, 'Penentuan Kelulusan Siswa Yayasan Cerdas Bakti Pertiwi Dengan Menggunakan Algoritma Naïve Bayes Dan Cross Validation', p. 9.
- [12] R. Dwijayanti and S. I. Haryudo, 'Prediksi Pembebanan Penyulang Transformator Distribusi Gardu Induk Petrokimia Dengan Metode Nonlinear Autoregressive Neural Network (NARNN)', vol. 08, p. 6, 2019.
- [13] B. Dietrich, J. Walther, M. Weigold, and E. Abele, 'Machine learning based very short term load forecasting of machine tools', *Appl. Energy*, vol. 276, p. 115440, Oct. 2020, doi: 10.1016/j.apenergy.2020.115440.