

## Penerapan *Artificial Neural Network* dalam Memprediksi Tingkat Inflasi di Indonesia

*(Application of Artificial Neural network s in Predicting Inflation Rates in Indonesia)*

**Nilam Dwi Cahyati<sup>1</sup>, Andi Agung<sup>2</sup>, Susan Dwi Saputri<sup>3\*</sup>, Noval Febrian Pattiasina<sup>4</sup>, Agusyarif Rezka Nuha<sup>5</sup>, Christari Lois Palit<sup>6</sup>**

<sup>1</sup>Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Pesantren Tinggi Darul Ulum  
Jl. KH. As'ad Umar No.1, Peterongan, Jombang, Jawa Timur 61481, Indonesia

<sup>2</sup>Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Pattimura

<sup>3,4</sup>Program Studi Ilmu Komputer, Fakultas Sains dan Teknologi, Universitas Pattimura  
Jl. Ir. M. Putuhena, Ambon, 97233, Indonesia

<sup>5</sup>Program Studi Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri  
Gorontalo

Jl. Prof. Dr. Ing. B.J. Habibie, Moutong, Tilongkabila, Kabupaten Bone Bolango, Gorontalo 96119, Indonesia

<sup>6</sup>Program Studi Pendidikan Matematika, Fakultas Matematika, Ilmu Pengetahuan Alam, dan Kebumian,  
Universitas Negeri Manado

Jl. Kampus Unima, Minahasa, Sulawesi Utara

Corresponding author's e-mail: [\\*susan.saputri@lecturer.unpatti.ac.id](mailto:susan.saputri@lecturer.unpatti.ac.id)

*Manuscript submitted:*  
15<sup>th</sup> November 2025

*Manuscript revision:*  
20<sup>th</sup> November 2025

*Accepted for publication:*  
22<sup>nd</sup> November 2025

### Abstract

*Bank Indonesia defines inflation as a general and sustained increase in prices, which if widespread will potentially affect other price increases resulting in a decrease in the value of money. The purpose of this research is to predict the inflation rate so that inflation can be controlled every month and provide information to the government, especially Bank Indonesia in the decision-making process to determine monetary policy and as an effort to maintain inflation stability in the future. This research implements the Artificial Neural network method with RapidMiner software. In this study using Inflation rate data S 11 years, from the period January 2013 to December 2023. The prediction results using the Artificial Neural network method for the inflation rate in Indonesia for the period January 2024 to December 2024 are consecutively obtained at 2.26%; 3.96%; 2.44%; 3.3%; 2.95%; 3.26%; 3.54%; 3.37%; 3.56%; 3.51%; 3.84%; 3.73% with an RMSE accuracy value of 0.909.*

**Keywords:** *Inflation; ANN; RMSE; Prediction; RapidMiner*



This article is an open access article distributed under the terms and conditions of the [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/).

**How to cite this article:**

N.D Cahyati, A. Agung, S. D. Saputri, N.V. Pattiasina, A. R. Nuha, and C. L. Palit., “Penerapan Artificial Neural Network dalam Memprediksi Tingkat Inflasi di Indonesia”, algorithm, vol. 1, no. 2, pp. 79-100, November. 2025.

Copyright © 2025 Author(s)

Journal homepage: <https://ojs3.unpatti.ac.id/index.php/algorithm>

**Research Article Open Access**


## 1. PENDAHULUAN

Kemajuan suatu negara dapat diukur melalui indikator ekonomi makro yang mencerminkan stabilitas dan kinerja perekonomian nasional [1]. Indikator-indikator yang termasuk diantaranya berupa nilai tukar, pendapatan per kapita, pengangguran, defisit perdagangan, dan inflasi. Diantara beberapa indikator makro ekonomi tersebut, inflasi merupakan indikator yang penting terhadap perekonomian suatu negara. Inflasi memiliki dampak besar pada sejumlah tujuan kebijakan makroekonomi, seperti pertumbuhan ekonomi, prospek lapangan kerja, distribusi pendapatan, dan neraca pembayaran [2]. Selain itu, krisis keuangan dapat terjadi di negara manapun akibat adanya inflasi yang tinggi [3].

Inflasi merupakan kenaikan harga barang dan jasa secara umum yang merupakan kebutuhan pokok masyarakat atau menurunnya daya beli mata uang suatu negara [4]. Kenaikan harga secara umum dan terus menerus inilah yang biasa disebut sebagai inflasi. Pengertian Inflasi tidak dapat didefinisikan sebagai kenaikan harga untuk satu atau dua barang, melainkan jika kenaikan tersebut signifikan atau meningkatkan harga barang yang lainnya. Sedangkan kebalikan dari adanya inflasi adalah deflasi [5].

Kestabilan inflasi merupakan prasyarat bagi pertumbuhan ekonomi yang berkesinambungan yang dapat memberikan manfaat bagi peningkatan kesejahteraan masyarakat. Gagasan bahwa inflasi yang tidak stabil dan relatif tinggi memiliki dampak negatif yang dapat merugikan kondisi sosial ekonomi masyarakat, oleh karena itu pentingnya menjaga inflasi agar tetap terkendali. Menurut Bank Indonesia, ada tiga dampak negatif dari inflasi yang tidak stabil dan tinggi. Pertama, tingkat inflasi yang tinggi akan menyebabkan hasil pendapatan riil masyarakat turun, sehingga akan menurunkan standar hidup masyarakat dan pada akhirnya membuat semua orang, terutama orang yang berasal dari kalangan ekonomi bawah akan menjadi bertambah miskin. Kedua, inflasi yang tidak dapat diprediksi akan menyulitkan para pelaku ekonomi dalam mengambil keputusan. Berdasarkan pengalaman empiris menunjukkan bahwa tingkat inflasi yang tidak stabil akan mempersulit masyarakat dalam membuat keputusan mengenai konsumsi, produksi dan investasi, yang dapat memperlambat pertumbuhan ekonomi. Ketiga, tingkat suku bunga riil domestik menjadi tidak kompetitif karena tingkat inflasi domestik yang lebih besar dibandingkan dengan negara-negara tetangga, yang dapat memberikan tekanan pada nilai rupiah [5].

Inflasi menjadi salah satu tantangan perekonomian terbesar dan paling kompleks di Indonesia bahkan di dunia sekalipun. Di Indonesia Tingkat Inflasi perlahan mulai menurun sejak akhir tahun lalu. Namun, inflasi Indonesia belum termasuk kategori rendah secara (*year on year/yoy*), Gubernur Bank Indonesia (BI) Perry Warjiyo menyampaikan dalam rapat kerja bersama dengan Komisi XI DPR RI (13/11/2023) bahwa laju inflasi memang mencatatkan ada penurunan, dan memprediksikan bahwa tahun 2024 akan mengalami penurunan, tetapi masih berada dalam kisaran 3% ke atas. Tingkat Inflasi di Indonesia dari tahun 2013-2023 dapat dilihat pada Gambar 1.



Gambar 1. Tingkat Inflasi di Indonesia

Mulai tahun 2013 tingkat inflasi di Indonesia mengalami fluktuatif namun mengindikasikan tingkat persentase yang relatif menurun setiap tahunnya, dan di tahun 2021 tingkat inflasi menunjukkan presentase cukup rendah di angka 1,56% yang mencerminkan kondisi ekonomi yang stabil. Namun, pada tahun 2022 terjadi lonjakan tingkat inflasi menjadi 4,21% menandakan bahwa adanya tekanan inflasi yang meningkat. Berdasarkan permasalahan tersebut, pemerintah terus memprioritaskan dalam upaya pengendalian inflasi karena dampaknya yang dapat merugikan, seperti memburuknya ketimpangan pendapatan, mengurangi tabungan domestik, menyebabkan kerugian dalam bidang perdagangan, mendorong pinjaman luar negeri yang berlebihan, dan dapat berpotensi memicu kerusuhan dalam dunia politik. Mengingat tingkat inflasi yang tinggi dapat menimbulkan berbagai dampak negatif yang merugikan, sehingga perlu dilakukan upaya untuk mencegahnya. Jika tidak dikendalikan, maka inflasi akan menghambat dalam proses pembangunan. Oleh karena itu, pemerintah membutuhkan prediksi tingkat inflasi supaya memperoleh informasi tentang perkiraan tingkat inflasi di masa yang akan datang.

Pada penelitian ini menggunakan metode prediksi *Artificial Neural network* (ANN) atau jaringan syaraf tiruan dengan menggunakan *software Rapidminer*. *Artificial Neural network* memiliki beberapa keunggulan yaitu metode ini memberikan hasil yang lebih optimal dari tingkat akurasi bahkan dalam jangka waktu yang lama sekalipun dibandingkan dengan metode peramalan lain yang menggunakan *time series*. Pemilihan metode ANN didasarkan pada penelitian sebelumnya yang menunjukkan bahwa metode ANN memberikan prediksi dengan tingkat error yang rendah dan akurasi yang tinggi [6], [7], [8].

## **2. METODE PENELITIAN**

### **2.1. Teknik Pengumpulan Data**

Data yang digunakan pada penelitian ini adalah data sekunder (*Time Series*) yang diperoleh dari website resmi Bank Indonesia, yaitu data Inflasi selama 11 Tahun berdasarkan nilai Indeks Harga Konsumen setiap bulannya, dari periode Januari 2013 sampai dengan Desember 2023 sehingga diperoleh data sebanyak 132 data Inflasi.

#### **2.1.1. Pengumpulan Data Sekunder**

Data yang digunakan merupakan data sekunder yang diperoleh melalui situs resmi Bank Indonesia melalui website [www.bi.go.id](http://www.bi.go.id) yaitu berupa data inflasi selama 11 Tahun yang berdasarkan nilai Indeks Harga Konsumen setiap bulannya dari periode Januari 2013 sampai dengan Desember 2023. Penelitian ini dilakukan dengan cara mengumpulkan, mempelajari, serta menelaah data-data sekunder yang berhubungan.

#### **2.1.2. Tinjauan Kepustakaan (*Library Research*)**

*Library Research* dilakukan untuk mendapatkan landasan teoritis yang berkaitan dengan topik yang akan diteliti. Dengan cara observasi, membaca, menelaah dan meneliti jurnal-jurnal, majalah, buku maupun literatur lainnya yang berkaitan erat dengan topik inflasi sehingga diperoleh informasi yang relevan sebagai dasar teori dan acuan untuk proses pengolahan data.

## **2.2. Teknik Analisis Data**

### **2.2.1. Pengumpulan Data**

Data yang digunakan merupakan data sekunder yang berupa data Inflasi selama 11 Tahun yang berdasarkan nilai Indeks Harga Konsumen (IHK) setiap bulannya dari periode Januari 2013 sampai dengan Desember 2023. Pemilihan data IHK dilakukan karena indikator ini secara

umum digunakan sebagai acuan resmi dalam pengukuran tingkat inflasi dan merepresentasikan perubahan harga barang dan jasa secara agregat. Data yang digunakan telah melalui publikasi resmi sehingga memiliki tingkat reliabilitas yang tinggi untuk keperluan analisis dan pemodelan.

### 2.2.2. Pre-Processing Data

Tahapan *pre-processing* merupakan proses awal yang bertujuan untuk memastikan kualitas data sebelum dilakukan pemodelan. Proses ini meliputi pembersihan data dengan menghilangkan *noise* untuk mengantisipasi adanya duplikasi data, serta pemeriksaan konsistensi data guna mendeteksi nilai yang bertentangan atau tidak wajar. Selain itu, dilakukan perbaikan terhadap kesalahan pencatatan atau kesalahan cetak agar data berada dalam kondisi yang siap diolah. Tahap *pre-processing* ini penting untuk meningkatkan akurasi model serta menghindari bias dalam proses *data mining*.

### 2.2.3. Pembagian Data

Data yang telah melalui tahap *pre-processing* selanjutnya dibagi menjadi dua bagian, yaitu data pelatihan (*data training*) dan data pengujian (*data testing*). Data pelatihan digunakan untuk melatih model Artificial Neural Network (ANN) agar mampu mengenali pola pada data inflasi, sedangkan data pengujian digunakan untuk mengevaluasi kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya. Pembagian data ini bertujuan untuk memastikan bahwa model yang dibangun tidak hanya mampu menghafal data, tetapi juga memiliki performa prediksi yang baik.

### 2.2.4. Penentuan Arsitektur ANN

Penentuan arsitektur ANN dilakukan dengan menetapkan struktur jaringan yang sesuai dengan karakteristik data inflasi. Parameter yang ditentukan meliputi jumlah *layer*, jumlah neuron pada setiap *layer*, serta fungsi aktivasi yang digunakan pada jaringan. Pemilihan arsitektur yang tepat bertujuan untuk memperoleh keseimbangan antara kompleksitas model dan kemampuan model dalam mempelajari pola data secara optimal. Arsitektur yang digunakan diharapkan mampu merepresentasikan hubungan nonlinier yang terdapat pada data inflasi.

### 2.2.5. Pelatihan Model

Proses pelatihan model dilakukan dengan menggunakan data pelatihan (*data training*) untuk menyesuaikan bobot dan bias pada jaringan ANN. Pelatihan dilakukan melalui mekanisme *forward propagation* untuk menghitung keluaran jaringan dan *backpropagation* untuk memperbarui bobot berdasarkan nilai kesalahan yang dihasilkan. Pada tahap ini ditentukan pula parameter pelatihan seperti jumlah iterasi (*epoch*) dan laju pembelajaran (*learning rate*). Penentuan parameter tersebut bertujuan untuk memastikan proses pembelajaran berlangsung secara stabil dan menghasilkan model dengan kinerja yang optimal.

### 2.2.6. Validasi Model

Tahap validasi model dilakukan dengan menggunakan data pengujian (*data testing*) yang terpisah dari data pelatihan. Validasi ini bertujuan untuk mengukur kinerja model ANN dalam memprediksi tingkat inflasi berdasarkan data yang belum digunakan pada proses pelatihan. Nilai *Root Mean Square Error* (RMSE) digunakan sebagai metrik evaluasi untuk mengukur tingkat kesalahan prediksi antara nilai aktual dan nilai hasil prediksi. Semakin kecil nilai RMSE yang diperoleh, maka semakin baik kinerja model dalam melakukan prediksi.

### 2.2.7. Evaluasi Model

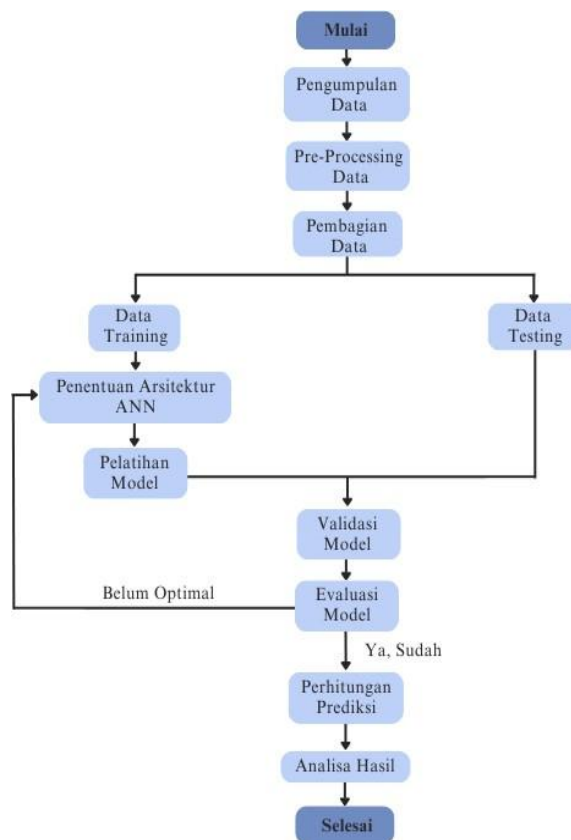
Evaluasi model dilakukan dengan menganalisis nilai RMSE yang diperoleh dari tahap validasi. Nilai tersebut digunakan untuk menilai kualitas prediksi model ANN dalam memodelkan pola inflasi. Apabila nilai RMSE relatif masih tinggi, maka dilakukan evaluasi lebih lanjut terhadap arsitektur jaringan atau parameter pelatihan yang digunakan. Proses ini bertujuan untuk melakukan optimasi model agar diperoleh hasil prediksi yang lebih akurat dan stabil.

### 2.2.8. Perhitungan Prediksi

Setelah model ANN dinyatakan memiliki kinerja yang memadai berdasarkan hasil validasi dan evaluasi, model tersebut digunakan untuk melakukan prediksi nilai inflasi. Prediksi dilakukan terhadap data baru yang belum pernah digunakan pada proses pelatihan maupun pengujian. Hasil prediksi ini diharapkan mampu memberikan gambaran nilai inflasi pada periode tertentu secara lebih akurat berdasarkan pola historis yang telah dipelajari oleh model.

### 2.2.9. Analisa Hasil

Tahap analisa hasil berfokus pada interpretasi terhadap hasil prediksi yang dihasilkan oleh model ANN. Analisis dilakukan untuk menilai sejauh mana model mampu menggambarkan pola perubahan inflasi dan kesesuaian antara nilai prediksi dengan nilai aktual. Selain itu, dilakukan evaluasi secara visual dan numerik untuk mengidentifikasi potensi kesalahan atau penyimpangan hasil prediksi. Hasil analisis ini menjadi dasar dalam penarikan kesimpulan mengenai kinerja model serta implikasinya terhadap penelitian. Tahapan analisis data yang dilakukan pada penelitian ini dapat dilihat pada Gambar 2.




Gambar 2. Tahapan Teknik Analisa Data

### 3. HASIL DAN PEMBAHASAN

#### 3.1. Analisis Deskriptif

Data yang digunakan pada penelitian ini adalah data Inflasi selama 11 tahun berdasarkan nilai Indeks Harga Konsumen setiap bulannya, dari periode Januari 2013 sampai dengan Desember 2023 sehingga diperoleh data sebanyak 132 data yang diperoleh dari *website* resmi Bank Indonesia, yang digambarkan pada Gambar 3 berikut.



Gambar 3. Plot Tingkat Inflasi Indonesia

Data yang digunakan adalah data tingkat Inflasi Indonesia periode bulanan, dari bulan Januari 2013 sampai dengan Desember 2023 yang total berjumlah 132 data, Nilai maksimum sebesar 8.79 yang terjadi pada bulan Agustus 2013. Salah satu penyebab tingginya inflasi pada bulan Agustus 2013 adalah adanya gejolak harga pada beberapa bahan pangan ditambah dengan permintaan yang cenderung masih rendah. Sedangkan nilai minimum sebesar 1.32 yang terjadi pada bulan agustus 2020. Dan untuk nilai rata-rata tingkat inflasi sebesar 4.07 Dengan nilai standar deviasi atau ukuran sebaran terhadap nilai rata-rata sebesar 1.95.

#### 3.2. Implementasi Metode Artificial Neural network dengan Software RapidMiner

##### 3.2.1 Pre-processing Data

*Pre-processing* merupakan Teknik pengolahan dalam data mining yang dilakukan untuk mengubah data mentah agar menjadi informasi yang lebih bersih dan dapat digunakan untuk pengolahan ke proses selanjutnya (Widiarti, 2022) dalam proses *pre-processing* berupa pembersihan data, seperti menghilangkan noise untuk menghindari duplikasi data, periksa data yang bertentangan dan kesalahan pada data untuk memperbaiki kesalahan cetak, sehingga data dapat diolah dan diproses *data mining*. Dalam *pre-processing* ini menggunakan pengecekan *missing value*, dapat dilihat pada Tabel 1 berikut :

Tabel 1. *Missing Value*

Variabel	Valid	Missing	Presentase Valid
Bulan	132	0	100%
Inflasi	132	0	100%



### 3.2.2 Pembagian Data

Pada penelitian kali ini, data presentase Inflasi berjumlah 132 data, yang akan dibagi kedalam dua data yaitu data *training* dan *testing* yang digunakan sebagai proses pembentukan dan pengujian model. Persentase percobaan digunakan untuk mencari model pembagian data dengan nilai *error* terkecil sehingga model yang digunakan dalam proses ANN memiliki hasil yang optimal sehingga persentase percobaan yang digunakan adalah 60% : 40%, 70% : 30% dan 80% : 20%. Untuk lebih jelas dapat dilihat pada Tabel 2 berikut.

Tabel 2. Pembagian Persentase Percobaan

Persentase Percobaan	Data Training	Data Testing	Total Data
60% : 40%	79	53	132
70% : 30%	92	40	132
80% : 20%	106	26	132

Berdasarkan data yang telah dibagi menjadi dua antara data training dan data testing yang selanjutnya akan dilakukan estimasi prediksi tingkat Inflasi untuk 12 bulan kedepannya, maka record data yang diperoleh dikosongkan untuk melakukan estimasi prediksi 12 bulan kedepannya pada bulan Januari 2024 sampai dengan Desember 2024.

### 3.2.3 Menentukan Arsitektur Model *Artificial Neural network*

Proses yang pertama yaitu proses training. Pada tahap ini menggunakan set role di Rapidminer , untuk pemilihan attribute data mana yang mau di prediksi, Setelah itu akan dilakukan proses windowing untuk mengetahui seberapa jauh peramalan akan dilakukan. Selanjutnya akan menuju operator *neural network* . Dalam operator ini terdapat penentuan parameter untuk mendapatkan arsitektur model terbaik *Artificial Neural network* . Untuk memilih arsitektur *neural network* yang terabik dan tepat, agar menghasilkan nilai akurasi yang cukup tinggi dan nilai *Root Mean Square Error* (RMSE) yang rendah, diperlukan pengaturan (*adjustment*) untuk parameter-parameter *neural network* antara lain *training cycle*, *learning rate*, *momentum* dan *hidden layer*.

Berikut ini adalah parameter-parameter yang membutuhkan adjustment:

1. *Training cycle* adalah jumlah perulangan training yang perlu dilakukan untuk mendapatkan error yang terkecil. Nilai *training cycle* bervariasi mulai dari 1 sampai dengan tak terhingga. Dalam penelitian ini ditentukan dengan cara melakukan uji coba memasukkan nilai dengan range 200 sampai dengan 1000 untuk *training cycle* [9].
2. *Learning rate* merupakan variabel yang dipakai dalam algoritma pembelajaran untuk mendapatkan bobot dari neuron [10]. Nilai yang cenderung besar mengakibatkan pembelajaran semakin cepat namun terdapat osilasi bobot, sedangkan nilai yang kecil mengakibatkan pembelajaran lebih lambat. Oleh karena itu, nilai *learning rate* harus berupa angka positif kurang dari 1. Dalam penelitian ini akan melakukan uji coba memasukkan nilai dengan range 0.001 sampai dengan 0.01
3. Momentum dipakai untuk menaikkan tingkat *convergence*, yang mampu mempercepat waktu pembelajaran dan juga mengurangi osilasi. Nilai momentum dalam interval dari 0




sampai 1. Sedangkan dalam penelitian ini akan melakukan uji coba memasukkan nilai dengan range 0.9 sampai dengan 0.1

4. *Hidden layer* merupakan tahap penentuan jumlah *hidden node* dan penentuan size atau jumlah neuron dari *hidden layer*, namun jika jumlah neuron terlalu kebanyakan akan menyebabkan *overfitting*, yaitu jumlah informasi dalam *training set* akan menjadi terbatas dan tidak mampu untuk melatih semua neuron dalam *hidden layer* [11].

Penelitian ini dilakukan dengan penyesuaian pada beberapa parameter *neural network* seperti jumlah *hidden layer*, *training cycle*, *learning rate* maupun jumlah momentum. Menurut Wilson & Martinez, jumlah input dan output menentukan jumlah lapisan tersembunyi dalam banyak kasus, meskipun ada metode lain juga [12]. Akurasi dapat ditingkatkan dengan meningkatkan jumlah lapisan tersembunyi [13], tetapi hal ini juga meningkatkan kompleksitas jaringan saraf dan waktu pelatihan. Dalam upaya mempersingkat periode pelatihan, hal ini dapat dihindari dengan menggunakan laju pembelajaran yang cukup tinggi supaya konvergensi dapat terjadi.

Dalam hal momentum, hubungan antara keduanya akan berbanding terbalik. Artinya, nilai momentum akan berkurang jika laju pembelajaran yang tinggi digunakan. Hanya melalui *trial and error* yaitu dengan memvariasikan nilai setiap parameter secara acak hingga menghasilkan model optimal dengan akurasi tertinggi maka model Jaringan Syaraf Tiruan terbaik dapat dibuat [14], [15].



Gambar 4. Proses *Neural Network* dalam RapidMiner

Dalam percobaan pertama menggunakan perbandingan 60% : 40% untuk data *training* dan *testing* dengan proses pemilihan parameter, sehingga menghasilkan model terbaik dengan 1 *hidden* dan nilai RMSE terkecil 1.485 seperti pada Tabel 3 berikut :

Tabel 3. Pembagian Data 60% : 40%

<i>Hidden node</i>	<i>Training cycles</i>	<i>Learning rate</i>	<i>Momentum</i>	Nilai RMSE
1	200	0.001	0.9	1.553
	200	0.001	0.1	1.554
	200	0.001	0.05	1.562

<i>Hidden node</i>	<i>Training cycles</i>	<i>Learning rate</i>	<i>Momentum</i>	<b>Nilai RMSE</b>
	200	0.001	0.001	1.57
	500	0.001	0.9	1.53
	500	0.001	0.1	1.519
	500	0.001	0.05	1.519
	500	0.001	0.001	1.519
	1000	0.001	0.9	1.521
	1000	0.001	0.1	1.546
	1000	0.001	0.05	1.543
	1000	0.001	0.001	1.54
	200	0.01	0.9	1.529
	200	0.01	0.1	1.546
	200	0.01	0.05	1.547
	200	0.01	0.001	1.548
	500	0.01	0.9	1.535
	500	0.01	0.1	1.526
	500	0.01	0.05	1.527
	500	0.01	0.001	1.528
	1000	0.01	0.9	1.537
	1000	0.01	0.1	1.519
	1000	0.01	0.05	1.52
	1000	0.01	0.001	1.52
2	200	0.001	0.9	1.637
	200	0.001	0.1	1.524
	200	0.001	0.05	1.524
	200	0.001	0.001	1.525
	500	0.001	0.9	1.495
	500	0.001	0.1	1.554

<i>Hidden node</i>	<i>Training cycles</i>	<i>Learning rate</i>	<i>Momentum</i>	<i>Nilai RMSE</i>
3	500	0.001	0.05	1.55
	500	0.001	0.001	1.548
	1000	0.001	0.9	1.676
	1000	0.001	0.1	1.629
	1000	0.001	0.05	1.623
	1000	0.001	0.001	1.617
	200	0.01	0.9	1.539
	200	0.01	0.1	1.637
	200	0.01	0.05	1.638
	200	0.01	0.001	1.64
	500	0.01	0.9	1.542
	500	0.01	0.1	1.5
	500	0.01	0.05	1.492
	500	0.01	0.001	1.485
	1000	0.01	0.9	1.564
	1000	0.01	0.1	1.648
	1000	0.01	0.05	1.64
	1000	0.01	0.001	1.633
	200	0.001	0.9	1.504
	200	0.001	0.1	1.534
	200	0.001	0.05	1.532
	200	0.001	0.001	1.53
	500	0.001	0.9	1.89
	500	0.001	0.1	1.572
	500	0.001	0.05	1.568
	500	0.001	0.001	1.566
	1000	0.001	0.9	2.881
	1000	0.001	0.1	1.645
	1000	0.001	0.05	1.641
	1000	0.001	0.001	1.637
	200	0.01	0.9	3.233
	200	0.01	0.1	1.512

<i>Hidden node</i>	<i>Training cycles</i>	<i>Learning rate</i>	<i>Momentum</i>	<i>Nilai RMSE</i>
	200	0.01	0.05	1.51
	200	0.01	0.001	1.514
	500	0.01	0.9	3.195
	500	0.01	0.1	2.036
	500	0.01	0.05	1.983
	500	0.01	0.001	1.939
	1000	0.01	0.9	3.455
	1000	0.01	0.1	3.107
	1000	0.01	0.05	3.03
	1000	0.01	0.001	2.949

Percobaan kedua menggunakan perbandingan dengan nilai persentase 70% : 30 % dengan proses pemilihan parameter sehingga mendapatkan model terbaik dengan RMSE terkecil 1.49 seperti pada Tabel 4 .

Tabel 4. Pembagian Data 70% : 30%

<i>Hidden node</i>	<i>Training cycles</i>	<i>Learning rate</i>	<i>Momentum</i>	<i>Nilai RMSE</i>
1	200	0.001	0.9	1.711
	200	0.001	0.1	1.508
	200	0.001	0.05	1.499
	200	0.001	0.001	1.49
	500	0.001	0.9	1.678
	500	0.001	0.1	1.607
	500	0.001	0.05	1.604
	500	0.001	0.001	1.6
	1000	0.001	0.9	1.648
	1000	0.001	0.1	1.678
	1000	0.001	0.05	1.671

<i>Hidden node</i>	<i>Training cycles</i>	<i>Learning rate</i>	<i>Momentum</i>	<i>Nilai RMSE</i>
2	1000	0.001	0.001	1.665
	200	0.01	0.9	1.53
	200	0.01	0.1	1.702
	200	0.01	0.05	1.703
	200	0.01	0.001	1.704
	500	0.01	0.9	1.502
	500	0.01	0.1	1.666
	500	0.01	0.05	1.669
	500	0.01	0.001	1.672
	1000	0.01	0.9	1.488
	1000	0.01	0.1	1.633
	1000	0.01	0.05	1.636
	1000	0.01	0.001	1.639
	200	0.001	0.9	1.741
	200	0.001	0.1	1.646
	200	0.001	0.05	1.632
	200	0.001	0.001	1.618
	500	0.001	0.9	1.656
	500	0.001	0.1	1.744
	500	0.001	0.05	1.741
	500	0.001	0.001	1.739
	1000	0.001	0.9	2.575
	1000	0.001	0.1	1.762
	1000	0.001	0.05	1.761
	1000	0.001	0.001	1.761
	200	0.01	0.9	3.57

<i>Hidden node</i>	<i>Training cycles</i>	<i>Learning rate</i>	<i>Momentum</i>	<i>Nilai RMSE</i>
3	200	0.01	0.1	1.748
	200	0.01	0.05	1.754
	200	0.01	0.001	1.759
	500	0.01	0.9	3.901
	500	0.01	0.1	1.789
	500	0.01	0.05	1.733
	500	0.01	0.001	1.683
	1000	0.01	0.9	3.833
	1000	0.01	0.1	2.893
	1000	0.01	0.05	2.767
	1000	0.01	0.001	2.654
	200	0.001	0.9	1.571
	200	0.001	0.1	1.695
	200	0.001	0.05	1.684
	200	0.001	0.001	1.672
	500	0.001	0.9	2.191
	500	0.001	0.1	1.765
	500	0.001	0.05	1.763
	500	0.001	0.001	1.761
	1000	0.001	0.9	3.311
	1000	0.001	0.1	1.754
	1000	0.001	0.05	1.758
	1000	0.001	0.001	1.761
	200	0.01	0.9	3.323
	200	0.01	0.1	1.541
	200	0.01	0.05	1.545

<i>Hidden node</i>	<i>Training cycles</i>	<i>Learning rate</i>	<i>Momentum</i>	<b>Nilai RMSE</b>
	200	0.01	0.001	1.556
	500	0.01	0.9	3.446
	500	0.01	0.1	2.301
	500	0.01	0.05	2.233
	500	0.01	0.001	2.174
	1000	0.01	0.9	3.489
	1000	0.01	0.1	3.459
	1000	0.01	0.05	3.386
	1000	0.01	0.001	3.311

Percobaan ketiga menggunakan perbandingan persentase 80% : 20 % dengan proses pemilihan parameter, sehingga diperoleh model terbaik dengan hasil RMSE terkecil 0.909 seperti pada Tabel 5.

Tabel 5. Pembagian Data 80% : 20%

<i>Hidden node</i>	<i>Training cycles</i>	<i>Learning rate</i>	<i>Momentum</i>	<b>Nilai RMSE</b>
1	200	0.001	0.9	2.035
	200	0.001	0.1	2.094
	200	0.001	0.05	2.069
	200	0.001	0.001	2.043
	500	0.001	0.9	1.744
	500	0.001	0.1	2.189
	500	0.001	0.05	2.2
	500	0.001	0.001	2.209
	1000	0.001	0.9	1.487
	1000	0.001	0.1	2.085
	1000	0.001	0.05	2.087
	1000	0.001	0.001	2.09



<i>Hidden node</i>	<i>Training cycles</i>	<i>Learning rate</i>	<i>Momentum</i>	<i>Nilai RMSE</i>
2	200	0.01	0.9	1.448
	200	0.01	0.1	2.03
	200	0.01	0.05	2.039
	200	0.01	0.001	2.045
	500	0.01	0.9	1.303
	500	0.01	0.1	1.734
	500	0.01	0.05	1.753
	500	0.01	0.001	1.77
	1000	0.01	0.9	1.264
	1000	0.01	0.1	1.525
	1000	0.01	0.05	1.535
	1000	0.01	0.001	1.544
	200	0.001	0.9	2.041
	200	0.001	0.1	2.376
	200	0.001	0.05	2.356
	200	0.001	0.001	2.335
	500	0.001	0.9	1.808
	500	0.001	0.1	2.391
	500	0.001	0.05	2.405
	500	0.001	0.001	2.417
	1000	0.001	0.9	1.686
	1000	0.001	0.1	2.138
	1000	0.001	0.05	2.153
	1000	0.001	0.001	2.168
	200	0.01	0.9	1.946
	200	0.01	0.1	2.03
	200	0.01	0.05	2.037

<i>Hidden node</i>	<i>Training cycles</i>	<i>Learning rate</i>	<i>Momentum</i>	<i>Nilai RMSE</i>
3	200	0.01	0.001	2.043
	500	0.01	0.9	0.909
	500	0.01	0.1	1.804
	500	0.01	0.05	1.812
	500	0.01	0.001	1.82
	1000	0.01	0.9	1.138
	1000	0.01	0.1	1.694
	1000	0.01	0.05	1.698
	1000	0.01	0.001	1.702
	200	0.001	0.9	2.049
	200	0.001	0.1	2.45
	200	0.001	0.05	2.435
	200	0.001	0.001	2.418
	500	0.001	0.9	1.841
	500	0.001	0.1	2.444
	500	0.001	0.05	2.458
	500	0.001	0.001	2.47
	1000	0.001	0.9	1.716
	1000	0.001	0.1	2.155
	1000	0.001	0.05	2.174
	1000	0.001	0.001	2.193
	200	0.01	0.9	1.753
	200	0.01	0.1	2.046
	200	0.01	0.05	2.054
	200	0.01	0.001	2.062
	500	0.01	0.9	1.032
	500	0.01	0.1	1.849

<i>Hidden node</i>	<i>Training cycles</i>	<i>Learning rate</i>	<i>Momentum</i>	<i>Nilai RMSE</i>
	500	0.01	0.05	1.855
	500	0.01	0.001	1.86
	1000	0.01	0.9	2.033
	1000	0.01	0.1	1.708
	1000	0.01	0.05	1.717
	1000	0.01	0.001	1.726

Berdasarkan hasil *trial and error* dari beberapa proses pengaturan (*adjustment*) parameter arsitektur *neural network* serta perbandingan persentase data *training* dan *testing* yang sudah dilakukan, dan diperoleh 1 arsitektur model terbaik dengan nilai RMSE yang terkecil, yaitu 0.909. Arsitektur tersebut sesuai dengan teori arsitektur jaringan syaraf, yakni dengan menambah jumlah *Hidden node*, meningkatkan jumlah *training cycle* dan nilai *learning rate* yang berbanding terbalik dengan momentum. Arsitektur yang terpilih tersebut tersusun atas 2 *Hidden node*, 500 *training cycle*, nilai *learning rate* terbesar 0.001 dan momentum 0.9.

### 3.2.4. Pelatihan Model Terbaik *Artificial Neural network*


Setelah melakukan proses trial error dalam beberapa percobaan arsitektur model *Artificial Neural network* dan untuk mengetahui ketepatan hasil prediksi dapat dilihat dari nilai *Root Mean Square Error* (RMSE). *Root Mean Square Error* (RMSE) adalah besarnya tingkat kesalahan dari hasil prediksi, dimana semakin kecil (mendekati 0) nilai RMSE, maka hasil prediksi akan semakin akurat (Suprayogi, 2012). Pada penelitian ini RMSE digunakan untuk mengevaluasi hasil prediksi *Artificial Neural network* (ANN) terhadap data asli untuk melihat seberapa besar akurat hasil prediksi yang akan dihasilkan. Dan setelah proses trial error dalam beberapa percobaan arsitektur diperoleh model terbaik yaitu dengan persentase 80%:20% untuk 2 *hidden layer*, 500 *training cycles*, 0.001 *learning rate* dan 0.9 Momentum yang menghasilkan nilai RMSE sebesar 0.909 yang artinya kemampuan model dapat mengikuti pola data adalah cukup baik. Berikut perbandingan nilai hasil prediksi dan nilai aktual, sebagai berikut:

Tabel 6. Hasil Perbandingan Data Aktual dan Prediksi

<b>Periode Bulan</b>	<b>Data Aktual</b>	<b>Data Prediksi</b>	<b>Selisih</b>
Nov-22	5.42	3.65	1.77
Dec-22	5.51	4.09	1.42
Jan-23	5.28	4.06	1.22
Feb-23	5.47	3.81	1.66
Mar-23	4.97	4.28	0.69
Apr-23	4.33	3.66	0.67
May-23	4	3.67	0.33
Jun-23	3.52	3.59	-0.07
Jul-23	3.08	3.48	-0.4
Aug-23	3.27	3.27	0

Periode Bulan	Data Aktual	Data Prediksi	Selisih
Sep-23	2.28	3.28	-1
Oct-23	2.56	2.44	0.12
Nov-23	2.86	2.93	-0.07
Dec-23	2.61	2.59	0.02

Berdasarkan hasil prediksi hampir mendekati nilai aktualnya, sehingga dapat dinyatakan bahwa model parameter yang digunakan termasuk cocok dengan data Inflasi Indonesia dan didukung dengan hasil akurasi RMSE yang relatif kecil yaitu 0,909.



Gambar 5. Hasil Perbandingan Data Aktual dan Prediksi


### 3.2.5 Hasil Prediksi Inflasi Indonesia

Hasil prediksi inflasi Indonesia periode Januari 2024 sampai Desember 2024 dengan arsitektur model terbaik yang telah didapatkan, dapat dilihat pada Tabel 7.

Tabel 7. Hasil Prediksi Inflasi Indonesia

Periode Bulan	Hasil Prediksi	Data Aktual
Jan-24	2.26 %	2.57 %
Feb-24	3.96 %	2.75 %
Mar-24	2.44 %	3.05 %
Apr-24	3.3 %	3.00 %
May-24	2.95 %	2.84 %
Jun-24	3.26 %	2.51 %
Jul-24	3.54 %	-
Aug-24	3.37 %	-
Sep-24	3.56 %	-
Oct-24	3.51 %	-
Nov-24	3.84 %	-

Periode Bulan	Hasil Prediksi	Data Aktual
Dec-24	3.73 %	-



Gambar 6. Diagram Hasil Prediksi Inflasi Indonesia

Dari Hasil prediksi yang sudah didapatkan menunjukkan bahwa nilai inflasi pada bulan Januari 2024 sampai dengan Desember 2024 cukup fluktuatif, dan hasil prediksinya hampir sama dengan data aktual yang diperoleh dari Bank Indonesia dari bulan Januari – Juni 2024 yang menunjukkan tingkat inflasi yang relatif masih naik turun. Selain itu, tingkat inflasi sebesar 3.96% yang menjadi inflasi terbesar akan terjadi pada 2024 tepatnya pada bulan Februari, serta prediksi pada Januari 2024 sebesar 2.26% akan diperkirakan menjadi inflasi terkecil. Berdasarkan hasil prediksi dan data aktual yang telah didapatkan meunjukkan bahwa pada bulan Februari 2024 sama – sama mengalami kenaikan tingkat inflasi daripada bulan sebelumnya.

Hal ini mengindikasikan bahwa kenaikan inflasi terjadi karena adanya kenaikan harga yang ditunjukan oleh naiknya sebagian besar indeks kelompok pengeluaran dan kenaikan inflasi juga dipicu oleh lonjakan harga komoditas pangan, komoditas yang lebih dominan memberikan andil seperti beras, cabai merah dan daging ayam ras. Sehingga dengan adanya kenaikan harga komoditas pangan tersebut dapat berperan dalam menekan daya beli masyarakat yang dapat menyebabkan tingginya tingkat inflasi (Badan Pusat Statistik, 2024).

Berdasarkan hasil dari penelitian ini, diharapkan dapat memberikan masukan kepada pemerintah khususnya Bank Indonesia untuk mendukung proses pengambilan keputusan dalam menentukan kebijakan moneter untuk menghindari kemungkinan terjadinya inflasi dan sebagai upaya dalam menjaga kestabilan inflasi di masa yang akan datang.

#### 4. KESIMPULAN DAN SARAN

##### KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa prediksi tingkat inflasi di Indonesia menggunakan metode *Artificial Neural Network* (ANN) yang

diimplementasikan melalui perangkat lunak RapidMiner menghasilkan arsitektur model terbaik dengan parameter 500 *training cycles*, *learning rate* sebesar 0,01, *momentum* 0,9, dua *hidden layer*, serta pembagian data pelatihan dan pengujian sebesar 80% dan 20%. Model ANN tersebut mampu memberikan kinerja prediksi yang baik dengan nilai *Root Mean Square Error* (RMSE) sebesar 0,909, yang menunjukkan tingkat kesalahan prediksi relatif rendah. Hasil prediksi inflasi Indonesia untuk periode Januari hingga Desember 2024 menunjukkan bahwa tingkat inflasi berada pada kategori rendah dengan nilai di bawah 10% untuk setiap bulan, sehingga model ANN dinilai cukup andal dalam memodelkan pola perubahan inflasi berdasarkan data historis. Meskipun demikian, penelitian selanjutnya disarankan untuk membandingkan metode ANN dengan metode prediksi lainnya serta menambahkan analisis ekonomi yang lebih mendalam dengan memasukkan faktor-faktor eksternal yang dapat memengaruhi fluktuasi inflasi, guna memperoleh model prediksi yang lebih optimal dan akurat. Selain itu, penggunaan perangkat lunak atau pendekatan pemodelan lain serta penerapan metode alternatif atau hibrida juga dapat dipertimbangkan untuk meningkatkan kualitas dan ketepatan hasil prediksi inflasi di Indonesia.

## REFERENSI

- [1] D. Wibowo and M. Firmansyah, "Melihat Hubungan Indikator Makro Ekonomi di Indonesia : Inflasi , Pengangguran , dan Pertumbuhan Ekonomi ?," vol. 2, no. 4, pp. 1–19, 2025.
- [2] E. Wati and P. Amalia, "Analisis Kebijakan Fiskal dan Kebijakan Moneter dalam Mengendalikan Inflasi dan Stabilitas Ekonomi," vol. 1, no. 3, pp. 91–101, 2025.
- [3] B. Martanto, S. Tan, and M. S. Hidayat, "Analisis tingkat inflasi di Indonesia Tahun 1998-2020 ( pendekatan error correction model )," vol. 16, no. 3, pp. 619–632, 2021.
- [4] Wind, "Inflasi dan IPH (Indeks Perkembangan Harga)," 2023. <https://tegalkab.bps.go.id/id/news/2023/11/27/336/senin-ngangenin---inflasi-dan-iph-indeks-perkembangan-harga-.html>.
- [5] D. Komunikasi, "Inflasi Agustus 2023 Tetap Terjaga," 2023, [Online]. Available: [https://www.bi.go.id/id/publikasi/ruang-media/news-release/Pages/sp\\_2524123.aspx?](https://www.bi.go.id/id/publikasi/ruang-media/news-release/Pages/sp_2524123.aspx?)
- [6] H. Jayadianti, T. A. Cahyadi, N. A. Amri, and M. F. Pitayandanu, "METODE KOMPARASI ARTIFICIAL NEURAL NETWORK PADA PREDIKSI CURAH HUJAN - LITERATURE REVIEW," vol. 14, no. 2, 2020.
- [7] S. C. Putro and M. I. Rosadi, "Penerapan *Artificial Neural network* untuk Prediksi Produksi Padi di Sumatera," pp. 487–494, 2023.
- [8] M. Miftakhudin, A. A. Murtopo, and Z. Arif, "Integrasi *Artificial Neural network* dan Algoritma Genetika untuk Prediksi Bencana Banjir Pesisir Kota Tegal," vol. 4, no. 3, pp. 840–848, 2025.
- [9] U. I. N. Sultan and S. Kasim, "Pengembangan Model ADDIE ( Analisis , Design , Development , Implemetation , Evaluation )," vol. 8, 2024.
- [10] L. Septiana and M. Informatika, "Pilar Nusa Mandiri Vol . IX No . 2 September 2013 PENERAPAN *NEURAL NETWORK* BERBASIS PARTICLE SWARM OPTIMIZATION UNTUK SELEKSI ATRIBUT PENENTUAN MAHASISWA Vol . IX No . 2 September 2013 Pilar Nusa Mandiri," vol. IX, no. 2, pp. 104–112, 2013.
- [11] I. Gunawan, "Optimasi Model *Artificial Neural network* Untuk Klasifikasi Paket Jaringan," vol. 14, no. 2, pp. 1–5, 2020.
- [12] D. R. Wilson and T. R. Martinez, "The Need for Small *Learning rates* on Large Problems," pp. 115–119, 2001.
- [13] S. Zahara *et al.*, "Pengaruh Jumlah *Hidden layer* dan Neuron pada Model Multilayer Perceptron untuk Prediksi Emas," vol. 8, no. 2, pp. 269–275, 2025.
- [14] R. Wine, G. Astray, J. C. Mejuto, I. Nevares, M. Alamo-sanza, and J. Simal-gandara, "Prediction

- Models to Control Aging Time in,” pp. 1–11, 2019, doi: 10.3390/molecules24050826.
- [15] M. S. Wibawa, “Pengaruh Fungsi Aktivasi , Optimisasi dan Jumlah Epoch Terhadap Performa Jaringan Saraf Tiruan,” vol. 11, no. 1, pp. 1–8, 2016.