

Prediksi Indeks Harga Konsumen (IHK) Kota Ambon Menggunakan *Elman Recurrent Neural Network* (ERNN)

Jefri Esna Thomas Radjabaycolle^{1*}, Jaka Permadi²

¹Jurusan Matematika FMIPA Universitas Pattimura, Jl. Ir M Putuhena, Ambon, Indonesia.

Email: jefriradja@gmail.com

² Prodi Teknologi Informasi, Politeknik Negeri Tanah Laut Kalimantan Selatan, Indonesia

Email: jakapermadi.88@politala.ac.id

Manuscript submitted : September 2020

Accepted for publication : November 2020

Abstract:

Indeks Harga Konsumen (IHK) is an economic indicator that can provide information on developments and changes in prices of goods and services that are predominantly consumed by the public within a certain period of time. In this study the method that we used is the Elman Recurrent Neural Network (ERNN). The research data that we used is Ambon City IHK data from 2016 to 2019. The data that used as research objects are: Food, Beverages, Cigarettes and Tobacco, Housing, Water, Electricity, Gas and Fuel, Clothing, Health, Education, Recreation, and Sport, Transportation, Communication and Financial Services which act as input variables. We obtained the results of training with 5 hidden layers at a maximum epoch of 100,000 obtained the smallest MAPE value of 1.1773. Also, the results of testing using the parameters in the experiment on the number of hidden layer neurons 20 obtained the smallest MAPE value of 0.461823.

2010 Mathematical Subject Classification : 97R40, 97R20

Keywords: ambon, ERNN, IHK, MAPE, prediction.

1. Pendahuluan

Indeks Harga Konsumen (IHK) merupakan indikator ekonomi yang dapat memberikan informasi mengenai perkembangan dan perubahan harga barang dan jasa yang dominan dikonsumsi masyarakat dalam kurun waktu tertentu. Berbagai macam peristiwa seperti ekonomi, politik, gejala masyarakat, dan perubahan harga barang/jasa yang cukup besar mengakibatkan pola konsumsi masyarakat yang cukup signifikan. Perhitungan IHK ditujukan untuk mengetahui perubahan harga dari sekelompok tetap barang/jasa yang pada umumnya dikonsumsi oleh masyarakat. Perubahan IHK dari waktu ke waktu menggambarkan tingkat kenaikan (inflasi) atau tingkat penurunan (deflasi) dari barang/jasa kebutuhan

rumah tangga sehari-hari [1]. Kenaikan atau penurunan harga barang/ jasa mempunyai kaitan yang erat sekali dengan kemampuan daya beli dari uang yang dimiliki masyarakat, terutama mereka yang berpenghasilan tetap. Tingkat perubahan IHK (inflasi/deflasi) yang terjadi, dengan sendirinya mencerminkan daya beli dari uang yang dipakai masyarakat untuk memenuhi kebutuhan sehari-hari. Semakin tinggi inflasi maka semakin rendah nilai uang dan semakin rendah daya belinya.

Sejak Januari 2014 hingga 2019 IHK secara keseluruhan meliputi 859 komoditas barang dan jasa yang kemudian diklasifikasikan menjadi 7 kelompok, yaitu kelompok bahan makanan; kelompok makanan jadi, minuman, rokok, dan tembakau; kelompok perumahan, air, listrik, gas, dan bahan bakar; kelompok sandang; kelompok kesehatan; kelompok pendidikan, rekreasi, dan olahraga; dan kelompok transport, komunikasi, dan jasa keuangan. [2]. Badan Pusat Statistik (BPS) mencatatkan tingkat inflasi pada tahun kalender 2019 (Desember 2019 dibanding 2018) sebesar 2,72 persen. Di tahun 2019, berdasarkan komponen inflasi tertinggi terjadi pada komponen harga barang bergejolak (*volatile prices*) yang mengalami inflasi sebesar 4,3 persen, dengan andil terhadap inflasi sebesar 0,77 persen. Adapun untuk inflasi inti di Desember 2019 sebesar 3,02 persen, lebih rendah dibandingkan dengan tahun sebelumnya yang sebesar 3,07 persen.

Pada penelitian ini metode yang akan digunakan adalah *Elman Recurrent Neural Network* (ERNN). Berdasarkan penelitian yang dilakukan oleh [3] Elman Recurrent Neural Network (ERNN) merupakan salah satu metode yang dapat dipakai dalam memprediksi data finansial. ERNN menyimpan informasi dari propagasi sebelumnya agar dapat diolah kembali sehingga galat yang dihasilkan menjadi lebih kecil. Hasil pembelajaran model ERNN pada data investasi Kabupaten Bogor baik dalam memprediksi fluktuatif nilai investasi pada data harian tetapi kurang baik dalam memprediksi data bulanan.

Dalam penelitian yang dilakukan oleh Afrianty dkk dalam [4], ERNN digunakan untuk memprediksi penjualan Pilus agar dapat meminimalisir terjadinya kerugian dengan parameter yaitu harga jual, biaya promosi, jumlah tempat pemasaran, *return* dan penjualan. Berdasarkan pengujian yang telah dilakukan, diperoleh akurasi tertinggi yaitu 90,25% dengan *epoch* 500 dan nilai *learning rate* 0.9 pada pembagian data 90% :10% sehingga dapat disimpulkan bahwa ERNN baik digunakan untuk prediksi penjualan Pilus.

Penelitian yang dilakukan oleh Danu dkk [5] menggunakan ERNN untuk memprediksi harga minyak mentah. Data yang digunakan dari bulan Januari 1986 hingga Desember 2011. Dari sistem yang dibuat diperoleh nilai NMSE sebesar 1.613 Dijelaskan bahwa dalam penelitian ini ERNN memiliki feedback loop sehingga mampu mempelajari dependensi waktu dari data latih dan memprediksi data yang akan datang menggunakan data uji.

Dalam [6] ERNN digunakan untuk memprediksi harga nilai tukar mata uang. ERNN dipilih karena memiliki proses pembelajaran yang cepat dan cocok untuk data *time series*.

Berdasarkan penelitian-penelitian yang telah dilakukan sebelumnya, maka Prediksi Indeks Harga Konsumen (IHK) di Kota Ambon akan diimplementasikan menggunakan *Elman Recurrent Neural Network* (ERNN).

1.1. Recurrent Neural Network (RNN)

Feedforward Neural Network (FNN) dan *Multilayer Perceptron* adalah jaringan yang umum dipakai dalam pemodelan jaringan *neural*. Salah satu tipe jaringan *neural* yang dikembangkan berdasarkan konsep FNN adalah *recurrent neural network*.

Recurrent neural network (RNN) adalah bagian dari *neural network* yang datanya diproses secara berkelanjutan *sequential*. Cara yang dilakukan RNN untuk dapat menyimpan informasi dari propagasi sebelumnya adalah dengan melakukan *looping* di dalam arsitekturnya, yang secara otomatis membuat

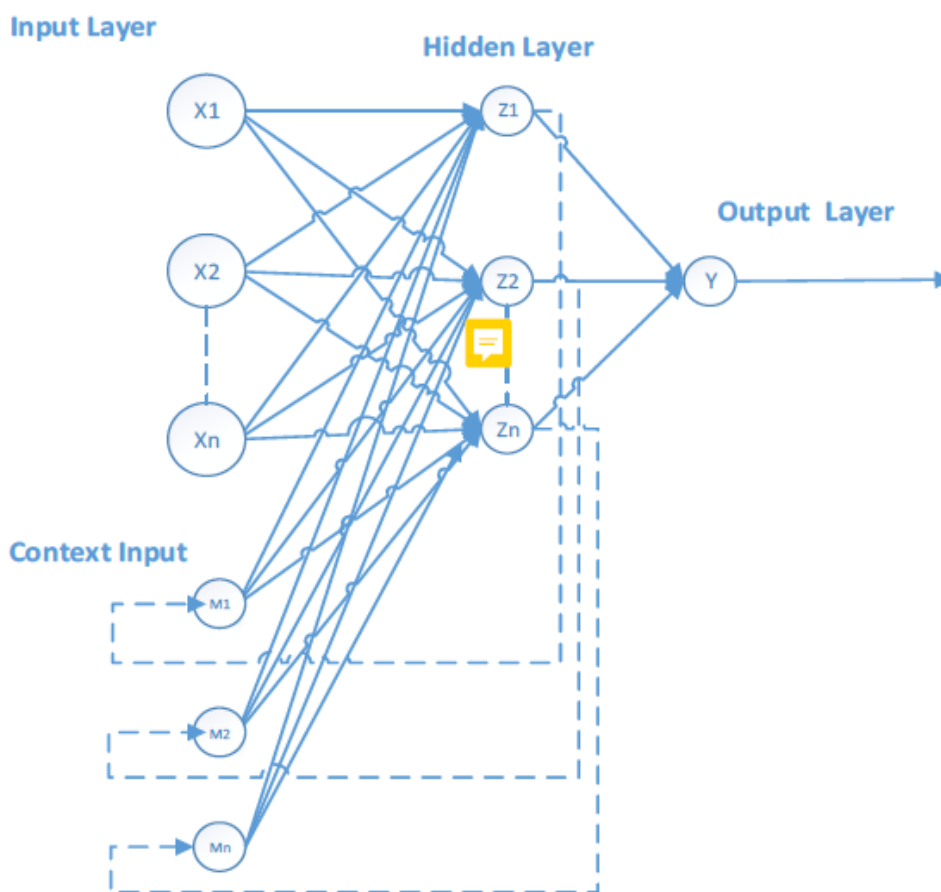
informasi dari masa lalu tetap tersimpan. Sifat dasar RNN membuktikan bahwa metode ini tepat diterapkan untuk data berbentuk *sequence* atau *list*, salah satunya adalah data *time series* (Wang *et al* 2016).

1.2. Elman Reccurent Neural Network (ERNN)

Recurrent neural network mempunyai dua jenis jaringan, yaitu *Elman recurrent neural network* dan *Hopfield recurrent neural network*. (Mikolov *et al* 2005 dalam Amaranggana 2016). Pada *network* ini lapisan *context* diperkenalkan, dimana lapisan ini akan menyimpan informasi dari *hidden layer* pada propagasi sebelumnya.

Elman recurrent neural network (Elman RNN) merupakan *neural network* yang sederhana karena hanya memiliki satu lapisan *hidden layer* serta koneksi umpan balik yang hanya terdapat pada lapisan *hidden layer*. *Output* pada *hidden layer* yang telah dihitung dengan fungsi aktivasi kemudian akan diteruskan ke lapisan *context layer* yang merupakan lapisan tambahan yang kemudian dipakai oleh jaringan sebagai masukan untuk memproses dan memproduksi *output* yang baru. Lapisan ini berguna sebagai memori dari hasil propagasi sebelumnya sehingga didapatkan pola untuk menentukan output pada propagasi waktu ke-t.


Arsitektur *Elman Recurrent Neural* (Radjabaycolle 2016) dapat dilihat pada Gambar 1 berikut:



Gambar 1. Arsitektur *Elmann Recurrent Neural Network*

Algoritma Elman Recurrent Neural Network

Jaringan *Elman vector input* akan dipropagasikan melalui *layer* bobot dan akan dikombinasikan dengan aktifasi sebelumnya memalui *layer* bobot *recurrent* tambahan yaitu U seperti pada Gambar 2 dimana U adalah bobot delay.



Gambar 2. Jaringan Elman

Setiap kali sebuah *pattern* disajikan, unit akan menghitung aktifasinya seperti halnya pada jaringan *feedforward*. Adapun tahapan dalam algoritma *JST Recurrent Elman* adalah sebagai berikut :

Tahap 1 : *Training* pola *input* atau *vector* saat *time* (*t*) seperti persamaan (1)

$$y(t) = f(net_j) \tag{1}$$

dengan jaringan *recurrent* seperti pada persamaan (2)

$$net_j(t) = \sum_i^n v_{ji} x_i(t) + \sum_h^m u_{jh} y_h(t-1) + \theta_j \tag{2}$$

Tahap 2 : *Output* jaringan ditentukan oleh lapisan *context* dan satu set *output* berbobot (*w*) seperti persamaan (3), yang kemudian dapat dijabarkan menjadi persamaan (4).

$$y(t) = g(net_k(t)) \tag{3}$$

$$net(t) = \sum_j^m w_{kj} y_j(t) + \theta_k \tag{4}$$

Tahap 3 : *Back propagation* untuk jaringan *recurrent*, Setiap bobot dimodifikasi, dimana fungsi biaya (kesalahan) sehubungan dengan bobot dihitung dan kemudian disesuaikan. Fungsi biaya yang digunakan dalam penelitian ini adalah *Mean Absolute Percentage Error* (MAPE). Berikut adalah rumus MAPE pada persamaan (5)

$$\text{MAPE} = \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{\hat{y}_i} \right| \times 100\% \quad (5)$$

Keterangan :

y_i : nilai aktual pada period eke i

\hat{y}_i : nilai forecast pada periode ke i

Tahap 4 : Menurut *gradient descent*, setiap perubahan bobot dalam jaringan harus sebanding dengan *gradient* negatif dari biaya sehubungan dengan tertentu yang tertarik untuk dimodifikasi. η adalah sebuah *learning rate* seperti pada persamaan (6).

$$\Delta w = -\eta \frac{\partial C}{\partial w} \quad (6)$$

Tahap 5 :Menggunakan aturan rantai dari diferensiasi, bobot berkaitan dengan *error* pada *output* dapat dinyatakan dengan persamaan (7).

$$\delta_{pk} = -\frac{\partial C}{\partial y_{pk}} \frac{\partial y_{pk}}{\partial \text{net}_{pk}} = (d_{pk} - y_{pk})g'(y_{pk}) \quad (7)$$

Sedangkan *error* pada *hidden layer* dinyatakan dengan persamaan (8)

$$\delta_{pj} = -\left(\sum_{k=1}^m \frac{\partial C}{\partial y_{pk}} \frac{\partial y_{pk}}{\partial \text{net}_{pk}} \frac{\partial \text{net}_{pk}}{\partial y_{pj}} \right) \frac{\partial y_{pj}}{\partial \text{net}_{pj}} = \sum_{k=1}^m \delta_{pk} w_{kj} f'(y_{pj}) \quad (8)$$

Dimana m adalah *neuron* pada lapisan *output*.

Tahap 6 : Perubahan bobot untuk *output* dinyatakan dengan persamaan (9). Sedangkan persamaan (10) untuk perubahan bobot

$$\Delta w_{kj} = \eta \sum_p^n \delta_{pk} y_{pj} \quad \text{input.} \quad (9)$$

$$\Delta v_{ji} = \eta \sum_p^n \delta_{pj} y_{pi} \quad (10)$$

Tahap 7 : Berdasarkan komponen waktu, perubahan bobot *recurrent* dapat dinyatakan seperti persamaan (11).

$$\Delta u_{jh} = \eta \sum_p^n \delta_{pj}(t) y_{ph}(t-1) \quad (11)$$

Tahap 8 : Pelatihan akan berhenti apabila $\text{error} < \text{target error}$.

2. Metode Penelitian

2.1. Data Penelitian

Data penelitian menggunakan data IHK Kota Ambon dari tahun 2016 sampai 2019. Data yang dipakai sebagai objek penelitian yaitu: Bahan Makanan, Makanan Jadi, Minuman, Rokok dan Tembakau, Perumahan, Air, Listrik, Gas dan Bahan Bakar, Sandang, Kesehatan, Pendidikan, Rekreasi, dan Olahraga, Transportasi, Komunikasi dan Jasa Keuangan sebagai variabel input (Tabel 1).

2.2. Variabel Penelitian

Variabel-variabel penelitian yang merupakan Indeks Harga Konsumen di Kota Ambon antara lain :

Tabel 1. Variabel Penelitian

Variabel	Nama Variabel
X1	Bahan Makanan
X2	Makanan Jadi, Minuman, Rokok dan Tembakau
X3	Perumahan, Air, Listrik, Gas dan Bahan Bakar
X4	Sandang
X5	Kesehatan
X6	Pendidikan, Rekreasi dan Olahraga
X7	Indeks Pembangunan Manusia menurut Kabupaten/Kota di Provinsi Maluku
X8	Transportasi, Komunikasi dan Jasa Keuangan

3. Hasil Penelitian

3.1. Deskripsi Data.

Data yang digunakan sesuai dengan data yang diambil dari profil maluku [3] dan disajikan pada tabel 2 sampai tabel 5 sebagai berikut:

Tabel 2. Indeks Harga Konsumen Kota Ambon Tahun 2016

Kelompok	Bulan											
	Jan	Feb	Mrt	Apr	Mei	Jun	Jul	Agts	Sept	Okt	Nov	Des
Bahan Makanan	0,97	3,02	-1,26	-4,41	1,12	-0,59	0,07	7,08	-1,73	-0,41	2,34	-1,94
Makanan Jadi, Minuman, Rokok & Tembakau	0,29	0,42	0,19	0,27	1,17	0,89	0,07	-0,1	-0,1	0,28	0,47	0,9
Perumahan, Air, Listrik, Gas, dan Bahan Bakar	0,42	-0,17	0,05	-0,02	0,13	0,34	0,44	0,08	0,11	0,23	0,14	0,03
Sandang	0,57	0,11	0,15	0,18	0,87	0,81	0,48	0,33	0,42	0,08	-0,05	0,06
Kesehatan	0,12	0,34	0,21	0,35	-0,09	0,21	0,74	0,13	0,2	0,2	0,07	-0,31
Pendidikan, Rekreasi, dan Olahraga	0	-0,35	-0,19	0,05	0,52	-0,14	0,27	0,02	-0,01	8,36	-0,41	-0,01
Transportasi, Komunikasi, dan Jasa Keuangan	-0,56	-2,21	-0,49	-0,54	5,17	0,47	1,21	-5,04	1,06	0,09	-0,5	4,07

Tabel 3. Indeks Harga Konsumen Kota Ambon Tahun 2017

Kelompok	Bulan											
	Jan	Feb	Mrt	Apr	Mei	Jun	Jul	Agts	Sept	Okt	Nov	Des
Bahan Makanan	0,99	-1,39	3,95	-5,67	1,13	12	4,76	-7,16	1,51	-4,72	-2,08	1,18
Makanan Jadi, Minuman, Rokok & Tembakau	0,05	0,79	0,14	-0,41	0,09	-0,08	0,06	0,46	-0,01	-0,04	0,06	0,08
Perumahan, Air, Listrik, Gas, dan Bahan Bakar	0,72	0,71	-0,01	0,86	0,18	0,72	0,23	0,02	0,49	0,41	-0,01	0,07
Sandang	0,01	0,14	0,3	0,35	0,06	0,36	-0,09	0,05	0,08	0,46	-0,03	-0,14
Kesehatan	0,05	0,67	0,19	0,14	0,3	0,2	0,03	0,12	0,14	0,09	0,03	0,02

Pendidikan, Rekreasi, dan Olahraga	-0,1	0,22	0,05	-0,01	-0,05	-0,07	0	0,23	0,13	0	0	0,1
Transportasi, Komunikasi, dan Jasa Keuangan	-0,6	-3,36	0,9	1,52	-0,55	0,19	-1,59	-1,76	3,54	-1,4	-0,54	0,19

Tabel 4. Indeks Harga Konsumen Kota Ambon Tahun 2018

Kelompok	Bulan											
	Jan	Feb	Mrt	Apr	Mei	Jun	Jul	Agts	Sept	Okt	Nov	Des
Bahan Makanan	2,84	1,64	-1,29	-2,64	4,39	0,5	-4,8	1,04	-4,18	-1,11	-1,8	2,13
Makanan Jadi, Minuman, Rokok & Tembakau	-0,12	0,14	-0,03	0,2	0,03	0,06	0,65	0,2	3,1	1,51	0,06	0,19
Perumahan, Air, Listrik, Gas, dan Bahan Bakar	0,19	0,04	0,23	0,02	0,1	0,08	0,15	0,22	0,1	0,96	1,03	0,09
Sandang	0,54	-,94	0,84	0,46	1,15	0,17	0,35	-0,25	0,22	0,38	1,39	0,02
Kesehatan	0,62	0,69	0,24	0,09	0,44	0,03	0,25	0	0,37	0,2	0,22	0,03
Pendidikan, Rekreasi, dan Olahraga	0,22	0	0,15	-0,15	0,05	0,1	0,53	0,07	-0,14	0,15	0,59	0,04
Transportasi, Komunikasi, dan Jasa Keuangan	-0,75	0,81	0,07	0,15	0,11	3,89	2,42	-0,74	0,68	1,08	3,89	3,33

Tabel 5. Indeks Harga Konsumen Kota Ambon Tahun 2019

Kelompok	Bulan											
	Jan	Feb	Mrt	Apr	Mei	Jun	Jul	Agts	Sept	Okt	Nov	Des
Bahan Makanan	0,48	0,16	-0,8	1,46	4,35	-0,3	1,57	-0,2	-0,1	0,12	-4,1	-3,2
Makanan Jadi, Minuman, Rokok & Tembakau	0,04	0,46	0,03	2,38	1,65	1,9	0,88	0,85	0,6	2,19	0,72	0,25
Perumahan, Air, Listrik, Gas, dan Bahan Bakar	0,26	-0,05	-0,04	-0,13	-0,17	0,16	0,09	0,17	-0,39	-0,03	-0,25	-0,01
Sandang	1,05	0,19	1,13	-0,02	0,28	3,09	-3,3	0,73	0,95	0,22	-0,1	-0,3
Kesehatan	0,12	0,07	0,3	0,02	0,48	0,32	0,25	0,49	0,72	0,06	0,16	0,3
Pendidikan, Rekreasi, dan Olahraga	0,03	0,02	0,17	0	0,03	-0,04	3,46	5,1	0	0,18	0,03	-0,06
Transportasi, Komunikasi, dan Jasa Keuangan	0,86	0,25	4,27	-3,06	1,62	-0,18	1,97	-3,22	-0,43	-0,1	0,36	1,63

3.2. Prediksi Menggunakan Elmann Recurrent Neural Network

Sebelum dilakukan prediksi, data terlebih dahulu mengalami *Preprocessing*. Proses ini bertujuan untuk memilih data yang digunakan sebagai data penelitian, kemudian data tersebut di normalisasi terlebih dahulu. Data dibagi menjadi 60% untuk *training* dan 40% untuk data *testing*. Hasil normalisasi untuk 60% data *training* dan untuk 40 % data *testing* dapat dilihat pada tabel 6 dan tabel 7 berikut.

Tabel 6. Data *Training* yang telah dinormalisasi

No	X1	X2	X3	Target
1	0,427310488058152	0,533748701973001	0,311526479750779	0,14797507788162
2	0,533748701973001	0,311526479750779	0,14797507788162	0,435098650051921
3	0,311526479750779	0,14797507788162	0,435098650051921	0,346313603322949

4	0,14797507788162	0,435098650051921	0,346313603322949	0,380581516095535
5	0,435098650051921	0,346313603322949	0,380581516095535	0,744548286604361
6	0,346313603322949	0,380581516095535	0,744548286604361	0,287123572170301
7	0,380581516095535	0,744548286604361	0,287123572170301	0,355659397715473
8	0,744548286604361	0,287123572170301	0,355659397715473	0,498442367601246
9	0,287123572170301	0,355659397715473	0,498442367601246	0,276220145379024
10	0,355659397715473	0,498442367601246	0,276220145379024	0,428348909657321
11	0,498442367601246	0,276220145379024	0,428348909657321	0,304776739356179
12	0,276220145379024	0,428348909657321	0,304776739356179	0,582035306334372
13	0,428348909657321	0,304776739356179	0,582035306334372	0,0825545171339564
14	0,304776739356179	0,582035306334372	0,0825545171339564	0,435617860851506
15	0,582035306334372	0,0825545171339564	0,435617860851506	1
16	0,0825545171339564	0,435617860851506	1	0,624091381100727
17	0,435617860851506	1	0,624091381100727	0,0051921079958463
18	1	0,624091381100727	0,0051921079958463	0,455347871235722
19	0,624091381100727	0,0051921079958463	0,455347871235722	0,131879543094496
20	0,0051921079958463	0,455347871235722	0,131879543094496	0,268951194184839
21	0,455347871235722	0,131879543094496	0,268951194184839	0,438213914849429
22	0,131879543094496	0,268951194184839	0,438213914849429	0,524402907580478
23	0,268951194184839	0,438213914849429	0,524402907580478	0,462097611630322
24	0,438213914849429	0,524402907580478	0,462097611630322	0,309968847352025
25	0,524402907580478	0,462097611630322	0,309968847352025	0,2398753894081
26	0,462097611630322	0,309968847352025	0,2398753894081	0,604880581516095
27	0,309968847352025	0,2398753894081	0,604880581516095	0,402907580477674

Tabel 7. Data *Testing* yang telah dinormalisasi

No	X1	X2	X3	Target
1	0,2398753894081	0,604880581516095	0,402907580477674	0,127725856697819
2	0,604880581516095	0,402907580477674	0,127725856697819	0,430944963655244
3	0,402907580477674	0,127725856697819	0,430944963655244	0,159916926272066
4	0,127725856697819	0,430944963655244	0,159916926272066	0,319314641744548
5	0,430944963655244	0,159916926272066	0,319314641744548	0,283489096573209
6	0,159916926272066	0,319314641744548	0,283489096573209	0,487538940809969
7	0,319314641744548	0,283489096573209	0,487538940809969	0,401869158878505
8	0,283489096573209	0,487538940809969	0,401869158878505	0,385254413291796
9	0,487538940809969	0,401869158878505	0,385254413291796	0,335410176531672
10	0,401869158878505	0,385254413291796	0,335410176531672	0,452751817237799
11	0,385254413291796	0,335410176531672	0,452751817237799	0,602803738317757
12	0,335410176531672	0,452751817237799	0,602803738317757	0,361370716510903
13	0,452751817237799	0,602803738317757	0,361370716510903	0,45846313603323
14	0,602803738317757	0,361370716510903	0,45846313603323	0,36656282450675
15	0,361370716510903	0,45846313603323	0,36656282450675	0,371754932502596
16	0,45846313603323	0,36656282450675	0,371754932502596	0,383177570093458
17	0,36656282450675	0,371754932502596	0,383177570093458	0,164070612668744
18	0,371754932502596	0,383177570093458	0,164070612668744	0,21079958463136

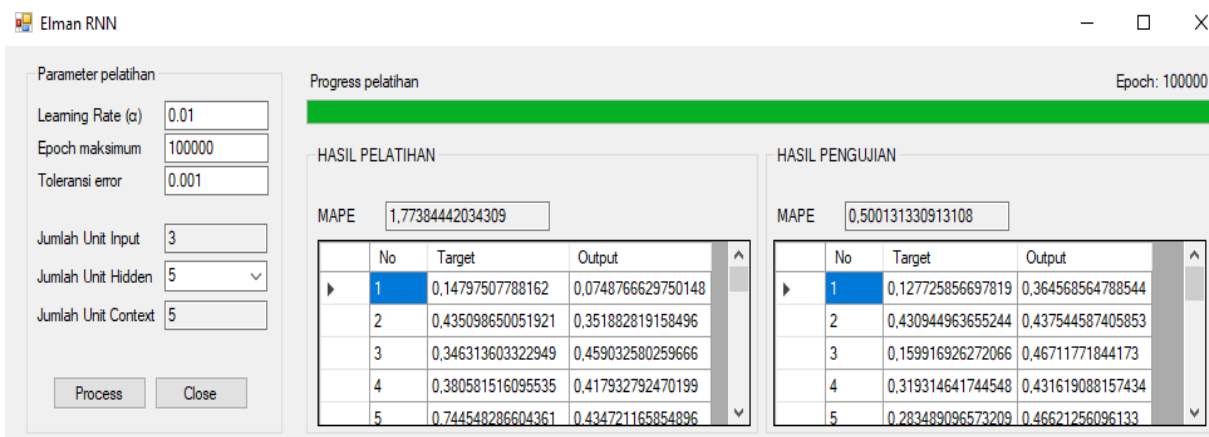
Jumlah *neuron* sangat mempengaruhi pada keakuratan hasil prediksi terhadap data yang digunakan dalam jaringan *Elman Recurrent Neural Network*. Jumlah *neuron* pada *hidden layer* yang cocok digunakan untuk

prediksi *bandwidth* diperoleh melalui proses percobaan dengan melakukan beberapa kali *training*. Sebagai acuan awal *learning rate* yang digunakan adalah 0.01 dan 0.02. Target *error* adalah 0,001 dengan *epoch* maksimal sebanyak 100.000 dimana proses akan berhenti apabila nilai fungsi kinerja kurang dari atau sama dengan target *error* yang telah ditentukan atau telah mencapai nilai maksimum *epoch*. Parameter pengujian dapat dilihat pada tabel 8.

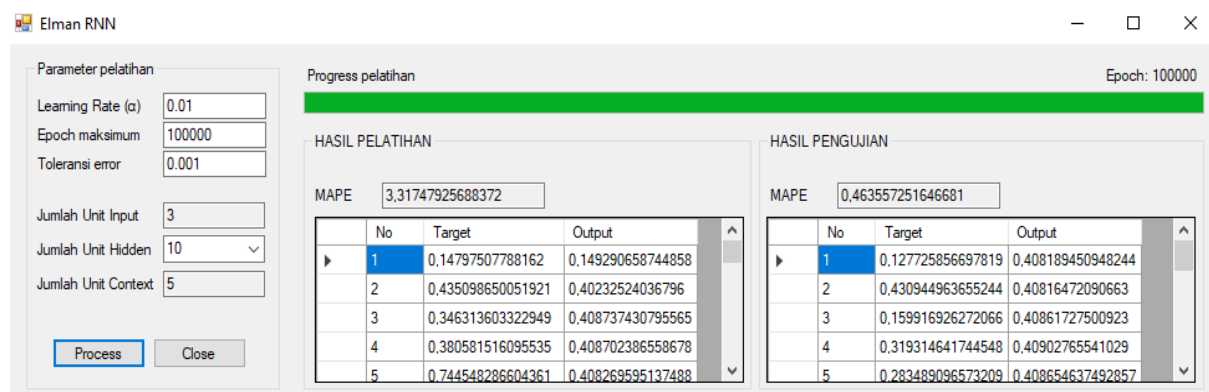
Tabel 8 Parameter pengujian jumlah *hidden neuron*

Parameter	Nilai	Keterangan
Target <i>error</i> (MAPE)	0,001	Target proses berhenti
<i>Learning rate</i>	0,01	Kecepatan pembelajaran sistem
Jumlah <i>Hidden</i>	5, 10, 15, 20	Jumlah lapisan tersembunyi
Jumlah unit <i>context</i>	5	
Maksimum <i>epoch</i>	100.000	Jumlah iterasi

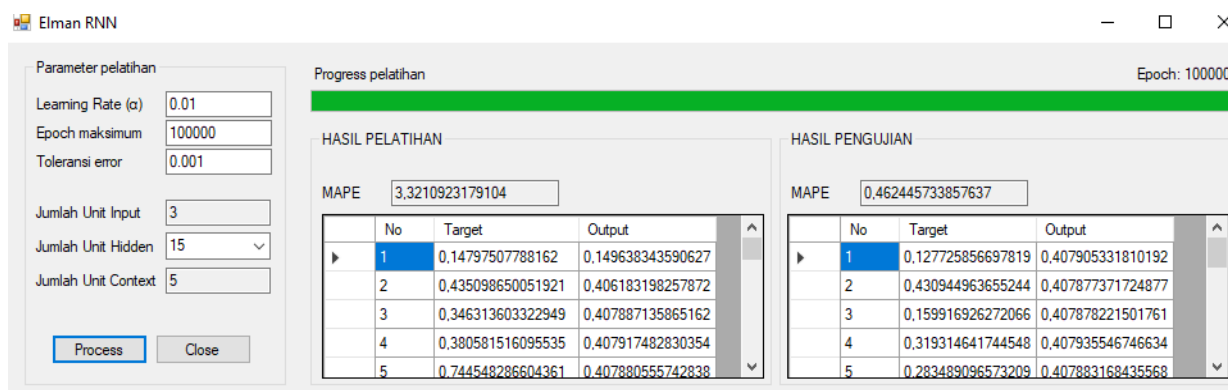
3.3. Hasil Output



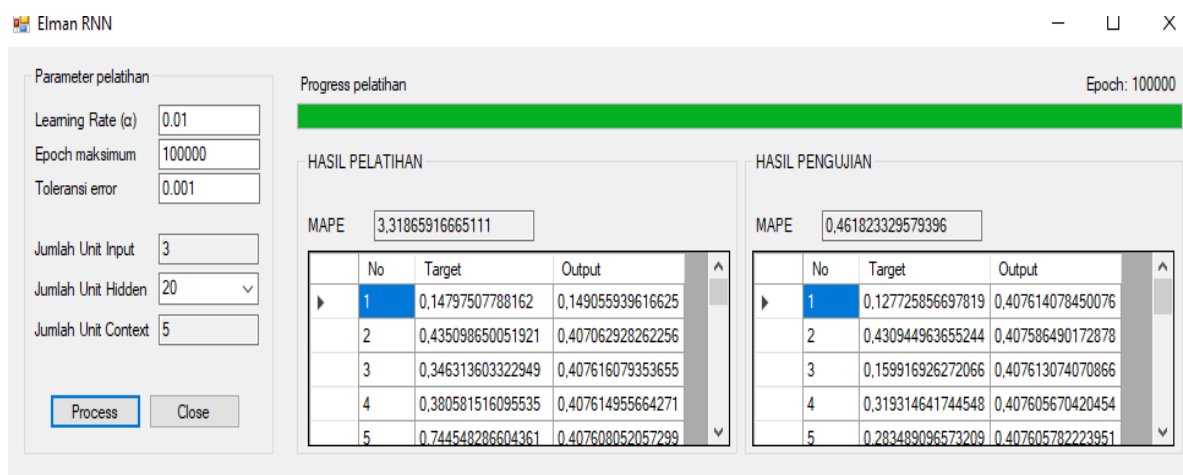
Gambar 3. Hasil Pelatihan dan Pengujian dengan *hidden layer* 5



Gambar 4. Hasil Pelatihan dan Pengujian dengan *hidden layer* 10



Gambar 5. Hasil Pelatihan dan Pengujian dengan *hidden layer* 15



Gambar 6. Hasil Pelatihan dan Pengujian dengan *hidden layer* 20

Berdasarkan prediksi yang telah dilakukan terhadap parameter pengujian diperoleh hasil yang dapat dilihat pada tabel 9 berikut ini.

Tabel 9 Hasil Prediksi

Hidden layer	MAPE	
	Training	Testing
5	1,1773	0,50013
10	3,31747	0,46355
15	3.32109	0,46244
20	3,31865	0,461823

Dari Tabel 9 tersebut dapat dilihat bahwa untuk proses *training* nilai MAPE terkecil diperoleh pada saat *hidden layer* berjumlah 5 yaitu sebesar 1,1773 dan untuk proses *testing* nilai MAPE terkecil diperoleh pada saat *hidden layer* berjumlah 20.

Pada penelitian ini data *testing* yang digunakan sebesar 40% dari total data yang digunakan, sehingga jumlah data yang digunakan sebanyak 18 vektor data. Data yang digunakan untuk *testing* merupakan data baru yang tidak diikutsertakan dalam proses *training*. Tingkat akurasi hasil proses *testing* sangat dipengaruhi oleh bobot hasil *training*, yang menunjukkan kemampuan jaringan dalam mengenali pola-pola yang dilatih. Berdasarkan hasil percobaan yang dilakukan, dengan target toleransi *error* sebesar 0.001 dengan nilai masing-masing parameter sama dengan nilai yang terdapat pada proses *training* untuk jumlah *neuron hidden layer*.

Hasil *testing* dengan jumlah data sebanyak 18 data menghasilkan nilai MAPE yang berbeda seperti yang ditunjukkan pada Tabel 9. Berdasarkan hasil *testing* diperoleh nilai MAPE terkecil yaitu pada jumlah *neuron hidden layer* 20 yaitu sebesar 0,461823.

4. Kesimpulan

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, maka diperoleh kesimpulan sebagai berikut, sistem yang dikembangkan mampu mengenali pola dan dapat melakukan prediksi terhadap indeks harga konsumen Kota Ambon dengan menggunakan metode jaringan saraf tiruan *Elman Recurrent Neural Network*. Hasil *training* dengan jumlah 5 *hidden layer* pada maksimum epoch 100.000 diperoleh nilai MAPE terkecil sebesar 1,1773. Kemudian hasil *testing* dengan menggunakan parameter pada percobaan pada jumlah *neuron hidden layer* 20 diperoleh nilai MAPE terkecil yaitu sebesar 0,461823.

Referensi

- [1] B. P. S. P. Maluku (2020) Indeks Harga Konsumen Kota Ambon dan Kota Tual 2019, Ambon: Badan Pusat Statistik Provinsi Maluku.
- [2] B. P. S. P. Maluku (2017) Indeks Harga Konsumen Kota Ambon dan Kota Tual 2016, Ambon: Badan Pusat Statistik Provinsi Maluku.
- [3] F. A. Y. Ritonga (2018) Prediksi investasi kabupaten bogor dengan metode elman recurrent neural network," Institut Pertanian Bogor, Bogor.
- [4] E. H. S. S. K. G. E. R. Iis Afrianty, (2018). Penerapan Jaringan Syaraf Tiruan Elman Recurrent Neural Network (ERNN) Untuk Prediksi Penjualan Pilus, *Seminar Nasional Teknologi Informasi, Komunikasi dan Industri (SNTIKI-10)*, pp. 158-164,.
- [5] A. T. W. M. D. S. Danu Sogi Purnomo (2014). Analisis dan implementasi elman recurrent neural network, Telkom University, Bandung,.
- [6] S. H. Ida Bagus Nyoman Pascima, (2018). Sistem Prediksi Harga Nilai Tukar Mata Uang Menggunakan Elman Recurrent Neural Network dengan Algoritma Genetika sebagai Metode Pembelajaran," *Journal of Mathematics and Natural Science*, vol. 25, no. 3, pp. 275-.
- [7] B. P. S. P. Maluku, (2018) Indeks Harga Konsumen Kota Ambon dan Kota Tual 2017, Ambon: Badan Pusat Statistik Provinsi Maluku.
- [8] B. P. S. P. Maluku, (2019) Indeks Harga Konsumen Kota Ambon dan Kota Tual 2018, Ambon: Badan Pusat Statistik Provinsi Maluku.
- [9] R. P. Jefri Radjabaycolle, (2016) prediksi penggunaan bandwidth menggunakan elman recurrent neural network, *Barekeng Jurnal Ilmu Matematika dan Terapan*, vol. 10, no. 2, pp. 127-135.

