

Peramalan Harga Kebutuhan Pokok (Beras) Pasca Pandemi Covid-19 dengan *Backpropagation Neural Network*

I Putu Oka Wisnawa, I Made Dwi Jendra Sulastra

Politeknik Negeri Bali, Bukit Jimbaran Kuta Selatan, Badung, Bali, Indonesia
okawisnawa@pnb.ac.id, dwijendrasulastra@pnb.ac.id

Paper received: 03-01-2023; revised: 15-01-2023; accepted: 30-01-2023

Abstract

As an algorithm in Artificial Neural Networks, Backpropagation Neural Networks have relatively good reliability and have been tested in forecasting case studies or data classification. Therefore, this algorithm was tested against Indonesian economic indicators (such as inflation rate, gross domestic product, Bank Indonesia rate, Rupiah exchange rate against USD, and prevailing electricity rate), to forecast the price of basic necessities, especially rice which is the staple food of Indonesian people. In this study, the Backpropagation Neural Network is tested again through a series of observation schemes. The dataset used is post-Covid-19 data, which is a picture of Indonesia's economic growth in 2022 after the pandemic, which is also affected by the issue of global economic recession in 2023. This means that the challenge is how a Backpropagation Neural Network can prove its reliability on data that has relatively grown volatile. However, based on the observation scheme that has been designed and tested, it turns out that the Backpropagation Neural Network is still able to provide a relatively high accuracy value, as evidenced by the relatively low MSE value of 0.02896. Of course, with the note that the preprocessing method used, the number of hidden layers and the number of epochs determine the performance of the reliability of the Backpropagation Neural Network in forecasting.

Keywords: artificial neural network; backpropagation neural network; forecasting

Abstrak

Sebagai sebuah algoritma dalam *Artificial Neural Network*, *Backpropagation Neural Network* memiliki keandalan yang relatif baik dan teruji dalam studi kasus peramalan ataupun klasifikasi data. Oleh karena itu, algoritma ini diujikan terhadap indikator-indikator ekonomi Indonesia (seperti nilai inflasi, produk domestik bruto, Bank Indonesia *rate*, nilai tukar Rupiah terhadap USD, dan tarif listrik yang berlaku), untuk meramalkan harga kebutuhan pokok, khususnya beras yang merupakan bahan makanan pokok masyarakat Indonesia. Dalam penelitian ini, *Backpropagation Neural Network* kembali diuji melalui serangkaian skema observasi. *Dataset* yang digunakan adalah data pasca pandemi Covid-19, yang merupakan gambaran pertumbuhan ekonomi Indonesia pada tahun 2022 pasca pandemi, yang juga terdampak isu resesi ekonomi global pada 2023. Ini berarti tantangannya adalah tentang bagaimana *Backpropagation Neural Network* mampu membuktikan keandalannya atas data yang memiliki pertumbuhan yang relatif fluktuatif. Namun, berdasarkan skema observasi yang telah dirancang dan diujikan, ternyata *Backpropagation Neural Network* tetap mampu memberikan nilai akurasi yang relatif tinggi, yang dibuktikan oleh nilai MSE yang relatif rendah, yaitu sebesar 0.02896. Tentunya dengan catatan bahwa metode *preprocessing* yang digunakan, jumlah *hidden layer* dan jumlah *epoch* menentukan performa keandalan *Backpropagation Neural Network* dalam melakukan peramalan.

Kata kunci: artificial neural network; backpropagation neural network; peramalan

1. Pendahuluan

Pandemi Covid-19 telah membuat perekonomian global menjadi lumpuh, Indonesia juga mengalami dampak tersebut (Astuti & Mahardhika, 2020; Habir & Wardana, 2020; Susilawati, Falefi, & Purwoko, 2020). Namun, kebijakan pemerintah sepertinya telah relatif membantu mengurangi besarnya dampak yang mungkin ditimbulkan. Meski demikian isu resesi ekonomi

global tetap saja berhembus. Salah satu yang akan terdampak adalah harga kebutuhan pokok, yang akan dirasakan oleh masyarakat pada lapisan akar rumput (Herliansyah, Nugroho, Ardilla, & Putra, 2020; Raja Pramudita, Ruslina, Dewi, Gustini, & Fakultas, 2022; Rayfinando et al., 2022). Sebagai negara agraris yang sebagian besar masyarakatnya mengonsumsi nasi sebagai makanan pokok, maka fluktuasi harga beras sangat berpengaruh bagi masyarakat. Kenaikan harga beras ini juga kadang akan mempengaruhi fluktuasi harga kebutuhan pokok lainnya di pasar, yang meskipun bukan faktor utama, namun tetap saja perlu untuk diperhatikan.

Meramalkan harga kebutuhan pokok ataupun komoditas mungkin tidak dapat berdampak signifikan dalam pengambilan kebijakan ekonomi. Namun, setidaknya dapat memberikan gambaran mengenai fluktuasi harga dan seberapa besar perubahan yang terjadi, dan risiko apa yang akan dihadapi. Seperti halnya sebuah sistem pendukung keputusan, *output* atas suatu sistem peramalan tidak menjadi penentu dalam pengambilan keputusan. Perannya adalah sebagai pembantu, yang menyediakan gambaran dari proses analisis terhadap histori fluktuasi harga atas *dataset* yang digunakan. Sehingga dalam implementasinya dapat berperan dalam pengambilan keputusan yang lebih bijaksana.

Backpropagation Neural Network adalah salah satu algoritma input yang memiliki keandalan yang baik dalam melakukan peramalan ataupun klasifikasi data di berbagai bidang (Guan, Dai, Zhao, & He, 2018; Ping & Fei, 2013; Siregar, Wanto, Tunas, & Pematangsiantar, 2017). Namun demikian, akurasi sebuah algoritma peramalan tergantung pada *dataset* yang digunakan, dan arsitektur yang dipilih. Ini berarti keandalan dari *backpropagation* akan diujikan terhadap indikator ekonomi Indonesia yang sedang mengalami pertumbuhan pasca pandemi covid-19, yang juga sedang terdampak isu resesi ekonomi global pada 2023.

Algoritma pada *Artificial Neural Network* akan cenderung bekerja lebih baik ketika nilai (pada variabel input dan *output*) yang berbeda, yang digunakan dalam proses *training* dan *testing*, berada pada skala yang lebih kecil. Oleh karena itu, menormalkan data sebelum melatih atau menguji model adalah proses awal yang sebaiknya dilakukan. Normalisasi juga membantu mengurangi kepekaan proses pelatihan ataupun pengujian terhadap skala sebaran distribusi data. Proses normalisasi ini akan menghasilkan koefisien yang lebih baik dalam *training* dan juga *testing*. Namun demikian, setiap metode tentunya akan menghasilkan nilai *output* yang relatif berbeda.

Berdasarkan pertimbangan tersebut, dalam penelitian ini *Backpropagation Neural Network* diimplementasikan untuk meramalkan harga kebutuhan pokok, yang dalam hal ini adalah beras, berdasarkan beberapa parameter yang mempengaruhi fluktuasi harga kebutuhan pokok yang juga terkait dengan indikator ekonomi Indonesia. *Dataset* yang digunakan adalah data pada tahun 2022, pasca covid-19. Tujuannya adalah untuk mengetahui tingkat akurasi peramalan *Backpropagation Neural Network* terhadap *dataset* harga beras dan indikator-indikator terkait yang sedang mengalami pertumbuhan pasca pandemi covid-19 sekaligus terdampak isu resesi ekonomi global, dimana nilai keandalan ini nantinya akan dilihat melalui nilai *Mean Squared Error* (MSE) dalam proses *training* ataupun *testing*.

2. Metode

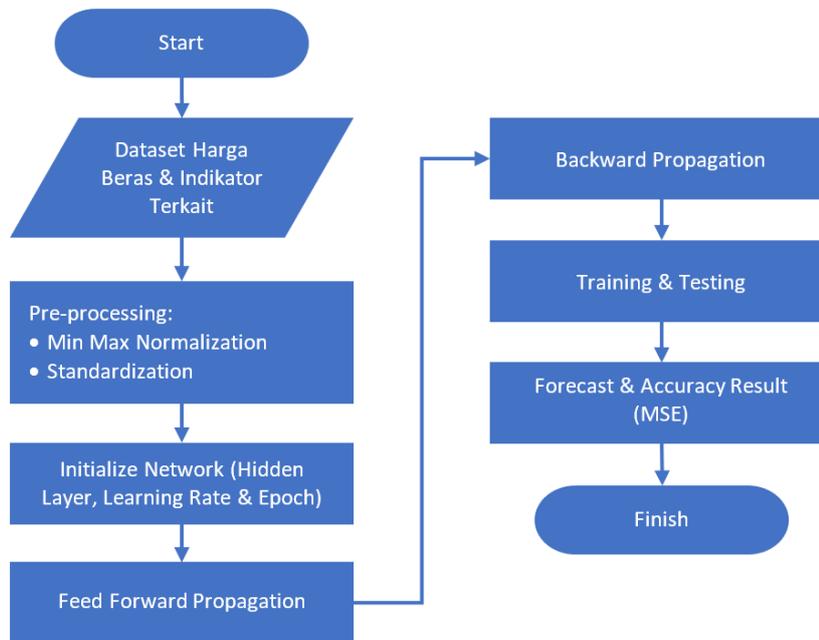
Metode penelitian yang dipilih adalah metode eksperimental dengan melakukan pengaturan atas parameter *hidden layer*, jumlah *epoch* dan juga metode *preprocessing* yang digunakan. Adapun data yang digunakan adalah data sekunder yang didapatkan dengan menganalisis data kebutuhan pokok dan indikator ekonomi Indonesia yang didapatkan dari *website* Kementerian Perdagangan Republik Indonesia, Bank Indonesia dan Perusahaan Listrik Negara (PLN) ('Badan Pusat Statistik', n.d.; 'Data Inflasi', n.d.; 'Nilai Tukar Mata Uang Asing Terhadap Rupiah | Satu Data Perdagangan', n.d.; 'Peta Harga Barang Pokok | Satu Data Perdagangan', n.d.; 'Produk Domestik Bruto (PDB) | Satu Data Perdagangan', n.d.; 'Tarif Adjustment', n.d.) .

Target sasarannya adalah untuk melihat pengaruh *hidden layer*, jumlah *epoch* dan juga metode *preprocessing* yang digunakan atas *dataset* harga beras, yang merupakan salah satu kebutuhan pokok yang terdampak Covid-19, terhadap akurasi peramalan. Data kebutuhan pokok pada tahun 2022, pasca Covid-19 dipilih dengan asumsi bahwa *dataset* ini adalah data yang memiliki pertumbuhan yang relatif signifikan, dan relatif fluktuatif, mengingat tahun 2022 adalah tahun transisi berakhirnya pandemi Covid-19 menuju isu resesi 2023, di mana pertumbuhan ekonomi baru saja terjadi setelah melewati krisis selama dua tahun sebelumnya. Adapun jumlah data yang digunakan pada penelitian ini adalah 12.410 baris data, dengan sebaran data sebagai berikut.

Tabel 1. Sample Dataset Peramalan Harga Beras berdasarkan Indikator-indikator Terkait

| Tanggal | Provinsi | Inflasi | Tarif Listrik | PDB Harga Berlaku (Triliun) | BI Rate | USD/IDR | Harga |
|------------|---------------------|---------|---------------|-----------------------------|---------|---------|-------|
| 2022-01-31 | Bangka Belitung | 2.18 | 1444.7 | 5091.17 | 3.5 | 15731 | 10375 |
| 2022-02-02 | Bali | 2.06 | 1444.7 | 5091.17 | 3.5 | 15737 | 9750 |
| 2022-03-04 | Sumatera Barat | 2.64 | 1444.7 | 5091.17 | 3.5 | 15542 | 12250 |
| 2022-04-02 | Kalimantan Timur | 3.47 | 1444.7 | 5091.17 | 3.5 | 15247 | 11574 |
| 2022-05-04 | DI Yogyakarta | 3.55 | 1444.7 | 4920.39 | 3.5 | 14875 | 10300 |
| 2022-06-04 | Gorontalo | 4.35 | 1444.7 | 4920.39 | 3.5 | 14958 | 11317 |
| 2022-07-08 | Papua | 4.94 | 1699.53 | 4920.39 | 3.5 | 14848 | 11250 |
| 2022-08-04 | DKI Jakarta | 4.69 | 1699.53 | 4920.39 | 3.75 | 14544 | 9611 |
| 2022-09-04 | Maluku | 5.95 | 1699.53 | 4513.66 | 4.25 | 14418 | 10741 |
| 2022-10-04 | Nusa Tenggara Barat | 5.71 | 1699.53 | 4513.66 | 4.75 | 14349 | 9708 |
| 2022-11-04 | Nusa Tenggara Timur | 5.42 | 1699.53 | 4513.66 | 5.25 | 14371 | 10278 |
| 2022-12-07 | Sulawesi Selatan | 5.51 | 1699.53 | 4513.66 | 5.5 | 14381 | 9297 |

Berdasarkan data yang ditampilkan pada Tabel 1, dapat dilihat bahwa ada beberapa indikator yang mempengaruhi fluktuasi harga. Indikator-indikator tersebut adalah tingkat Inflasi, Tarif Listrik, Produk Domestik Bruto (PDB) Harga Berlaku, Bank Indonesia (BI) *Rate*, dan Nilai Tukar Rupiah terhadap USD. Pada penelitian ini, indikator-indikator tersebut akan berperan sebagai parameter input atas *Backpropagation Neural Network*, sedangkan Harga Beras akan berperan sebagai *output* peramalan. Ini berarti bahwa harga beras ditentukan berdasarkan nilai yang diinputkan pada setiap parameter input.



Gambar 1. Prosedur Peramalan Harga dalam *Back Propagation Neural Network*

Dataset tersebut kemudian dibagi menjadi data *training* untuk pelatihan input dan data *testing* untuk pengujian atas arsitektur input yang dibangun. Adapun perbandingan jumlah data *training* dan data *testing* adalah 80:20. Sehingga jumlah data *training* yang digunakan adalah 9.928 baris data, sedangkan jumlah data *testing*nya adalah 2.482 baris data. Sebelum data tersebut diolah di dalam arsitektur *Backpropagation Neural Network*, data tersebut perlu dinormalisasi terlebih dahulu sebagai bagian dari *preprocessing*. Adapun metode yang diobservasi dalam penelitian ini adalah metode *Min Max Normalization* dan Metode *Standardization*. Kedua metode ini tidak digunakan secara sekuensial. Namun diobservasi secara terpisah atas *dataset* yang sama, untuk melihat pengaruhnya atas nilai MSE yang dihasilkan oleh *Backpropagation Neural Network*. Pada metode *Min Max Normalization*, distribusi statistik data dinormalisasi melalui perhitungan dalam notasi berikut ini.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Sedangkan *Standardization* adalah teknik normalisasi yang mengubah distribusi statistik data melalui bantuan nilai standar deviasi. Normalisasi dapat dilakukan dengan bantuan notasi di bawah ini.

$$x_{norm} = \frac{x - \mu}{\sigma} \quad (2)$$

Dimana, x adalah data *training* atau data *testing* yang akan dinormalisasi, μ adalah nilai *mean* dari data *training* atau data *testing*, dan s adalah standar deviasi dari data *training* atau data *testing*.

Sebagaimana yang dijelaskan dalam Gambar 1, setelah melakukan normalisasi data, maka dilakukan inisialisasi atas arsitektur *backpropagation* yang akan dibangun. Selanjutnya data yang telah dinormalisasi akan diproses di dalam arsitektur tersebut melalui proses *feedforward propagation* dan *backward propagation* yang merupakan proses *sequential* yang terjadi dalam satu *epoch* dalam arsitektur *Backpropagation Neural Network*. Fase ini akan diulang selama beberapa siklus *epoch* yang sebut sebagai proses *training*. Sebuah siklus akan menghasilkan pembobotan yang baru untuk proses *feed forward propagation* dan *backward propagation* di siklus berikutnya.

Metode yang digunakan untuk mengukur akurasi atas arsitektur yang diobservasi adalah *Mean Squared Error (MSE)*, yang merupakan nilai kesalahan kuadrat rata-rata atas model peramalan yang digunakan. Proses perhitungannya dapat dilakukan melalui notasi berikut ini.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (3)$$

Adapun Y_i adalah nilai nilai aktual, sedangkan \hat{Y}_i adalah nilai prediksi atau hasil peramalan, dan n adalah jumlah data. Nilai MSE akan selalu bernilai positif, dimana semakin mendekati nol nilainya, maka ini berarti semakin bagus akurasi peramalannya.

3. Hasil dan Pembahasan

Terdapat dua metode yang diobservasi pada proses *preprocessing*, yaitu *Min Max Normalization* dan *Standardization*. Data yang ditampilkan pada Tabel 2, adalah *output* dari proses *Min Max Normalization* atas *sample dataset* yang ditampilkan pada Tabel 1.

Tabel 2. Sample Dataset Setelah Min Max Normalization

| Tanggal | Provinsi | Inflasi | Tarif Listrik | PDB Harga Berlaku (Triliun) | BI Rate | USD/ IDR | Harga |
|------------|------------------|---------|---------------|-----------------------------|---------|----------|--------|
| 2022-01-31 | Bangka | 0.0308 | 0 | 1 | 0 | 0.9957 | 0.3651 |
| 2022-02-02 | Belitung | | | | | | |
| 2022-02-02 | Bali | 0 | 0 | 1 | 0 | 1 | 0.1534 |
| 2022-03-04 | Sumatera Barat | 0.1491 | 0 | 1 | 0 | 0.8595 | 1 |
| 2022-04-02 | Kalimantan Timur | 0.3625 | 0 | 1 | 0 | 0.647 | 0.7711 |
| 2022-05-04 | DI Yogyakarta | 0.383 | 0 | 0.7043 | 0 | 0.379 | 0.3397 |
| 2022-06-04 | Gorontalo | 0.5887 | 0 | 0.7043 | 0 | 0.4388 | 0.6841 |
| 2022-07-08 | Papua | 0.7404 | 1 | 0.7043 | 0 | 0.3595 | 0.6614 |
| 2022-08-04 | DKI Jakarta | 0.6761 | 1 | 0.7043 | 0.125 | 0.1405 | 0.1063 |
| 2022-09-04 | Maluku | 1 | 1 | 0 | 0.375 | 0.0497 | 0.489 |

| Tanggal | Provinsi | Inflasi | Tarif Listrik | PDB Harga Berlaku (Triliun) | BI Rate | USD/IDR | Harga |
|------------|---------------------|---------|---------------|-----------------------------|---------|---------|--------|
| 2022-10-04 | Nusa Tenggara Barat | 0.9383 | 1 | 0 | 0.625 | 0 | 0.1392 |
| 2022-11-04 | Nusa Tenggara Timur | 0.8638 | 1 | 0 | 0.875 | 0.0159 | 0.3322 |
| 2022-12-07 | Sulawesi Selatan | 0.8869 | 1 | 0 | 1 | 0.0231 | 0 |

Sedangkan data yang ditampilkan pada Tabel 3, adalah *output* dari metode *Standardization* atas *sample dataset* yang ditampilkan pada Tabel 1. Proses ini menghasilkan nilai dengan rentang -1 hingga 1.

Tabel 3. Sample Dataset Setelah Standardization

| Tanggal | Provinsi | Inflasi | Tarif Listrik | PDB Harga Berlaku (Triliun) | BI Rate | USD/IDR | Harga |
|------------|---------------------|---------|---------------|-----------------------------|---------|---------|--------|
| 2022-01-31 | Bangka Belitung | - | -1 | 1.0297 | - | 1.5921 | - |
| 2022-02-02 | Bali | 1.5168 | -1 | 1.0297 | 0.6928 | 1.6038 | 0.1875 |
| 2022-03-04 | Sumatera Barat | - | -1 | 1.0297 | 0.6928 | 1.2225 | 1.9752 |
| 2022-04-02 | Kalimantan Timur | 1.1724 | -1 | 1.0297 | 0.6928 | 0.6457 | 1.1955 |
| 2022-05-04 | DI Yogyakarta | -0.491 | -1 | 0.3247 | 0.6928 | -0.0816 | -0.274 |
| 2022-06-04 | Gorontalo | 0.1079 | -1 | 0.3247 | 0.6928 | 0.0807 | 0.899 |
| 2022-07-08 | Papua | 0.5497 | 1 | 0.3247 | 0.6928 | -0.1344 | 0.8217 |
| 2022-08-04 | DKI Jakarta | 0.3625 | 1 | 0.3247 | 0.3464 | -0.7288 | - |
| 2022-09-04 | Maluku | 1.3059 | 1 | -1.3544 | 0.3464 | -0.9752 | 0.2346 |
| 2022-10-04 | Nusa Tenggara Barat | 1.1262 | 1 | -1.3544 | 1.0392 | -1.1101 | - |
| 2022-11-04 | Nusa Tenggara Timur | 0.9091 | 1 | -1.3544 | 1.7321 | -1.0671 | 0.2994 |
| 2022-12-07 | Sulawesi Selatan | 0.9765 | 1 | -1.3544 | 2.0785 | -1.0475 | -1.431 |

Setelah mengalami proses normalisasi data, maka kedua *dataset* tersebut diproses di dalam skema observasi atas arsitektur *backpropagation* yang telah dirancang sebelumnya. Terdapat beberapa arsitektur yang diobservasi dalam penelitian ini dengan skema pengujian sebagaimana yang ditunjukkan dalam Tabel 4.

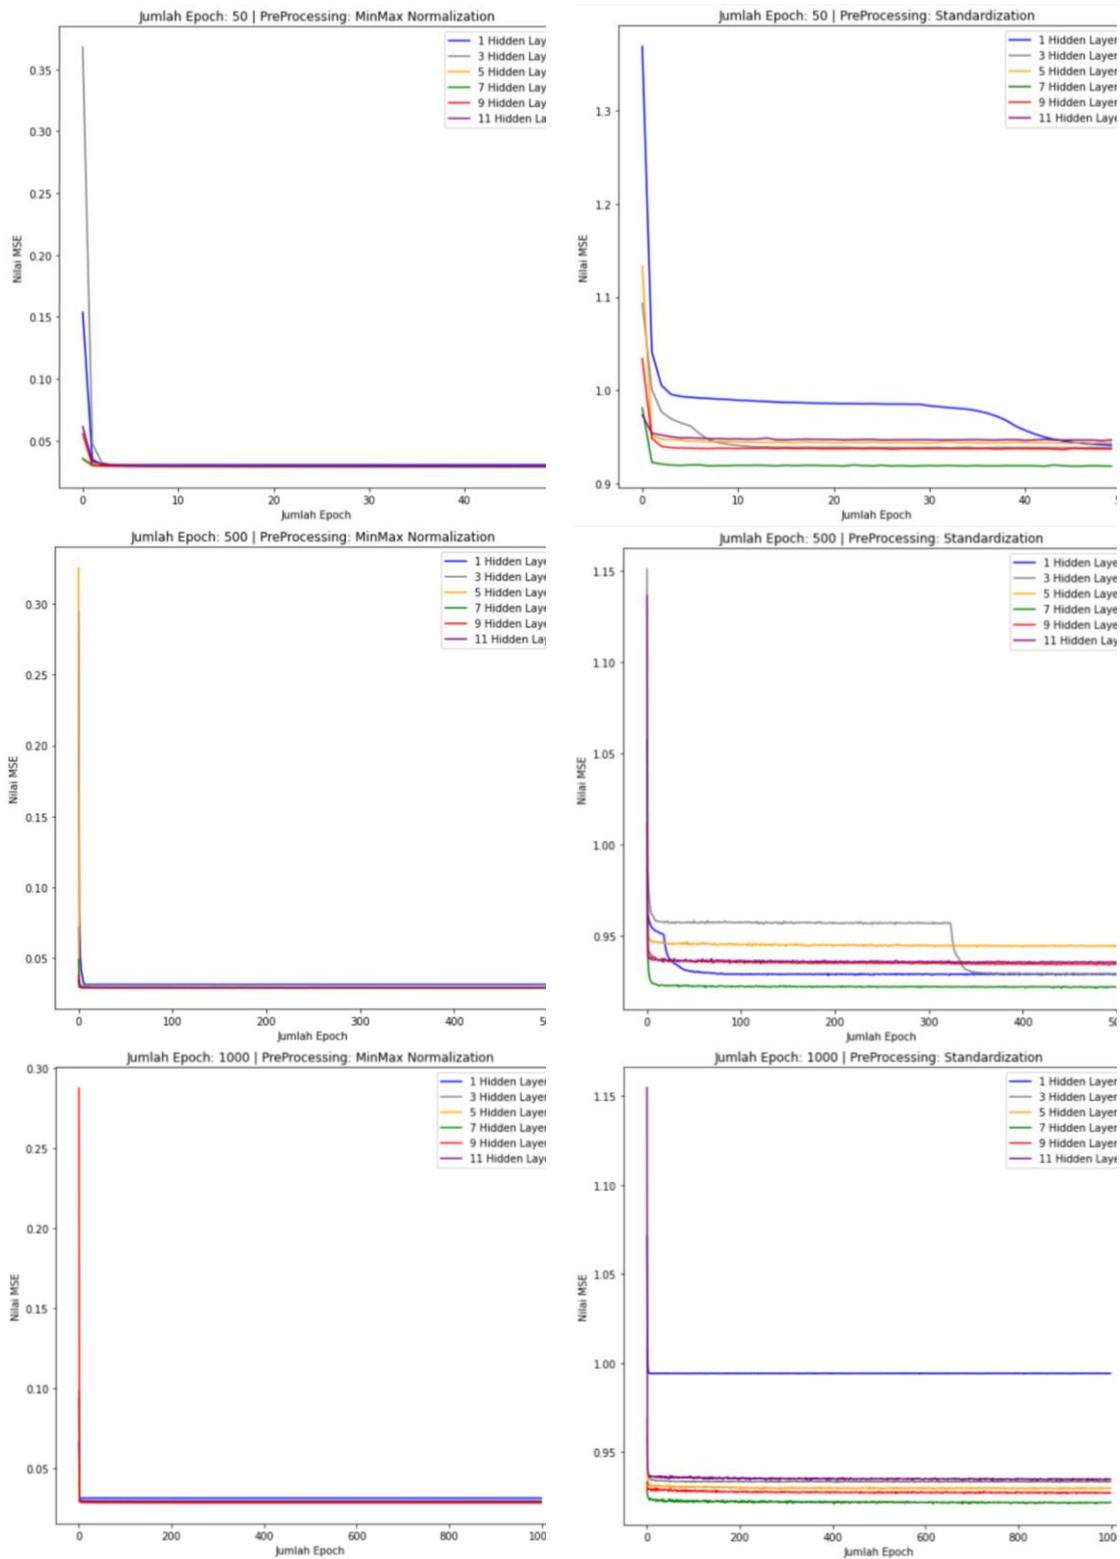
Tabel 4. Skema Observasi dalam Eksperimen

| PreProcessing | Input | Hidden Layer | Output | Learning Rate | Jumlah Epoch |
|-----------------|-------|--------------|--------|---------------|--------------|
| Min Max | 5 | 1 | 1 | 0.001 | 50 |
| Normalization | 5 | 3 | 1 | 0.001 | 50 |
| | 5 | 5 | 1 | 0.001 | 50 |
| | 5 | 7 | 1 | 0.001 | 50 |
| | 5 | 9 | 1 | 0.001 | 50 |
| | 5 | 11 | 1 | 0.001 | 50 |
| | 5 | 1 | 1 | 0.001 | 500 |
| | 5 | 3 | 1 | 0.001 | 500 |
| | 5 | 5 | 1 | 0.001 | 500 |
| | 5 | 7 | 1 | 0.001 | 500 |
| | 5 | 9 | 1 | 0.001 | 500 |
| | 5 | 11 | 1 | 0.001 | 500 |
| | 5 | 1 | 1 | 0.001 | 1000 |
| | 5 | 3 | 1 | 0.001 | 1000 |
| | 5 | 5 | 1 | 0.001 | 1000 |
| Standardization | 5 | 7 | 1 | 0.001 | 1000 |
| | 5 | 9 | 1 | 0.001 | 1000 |
| | 5 | 11 | 1 | 0.001 | 1000 |
| | 5 | 1 | 1 | 0.001 | 50 |
| | 5 | 3 | 1 | 0.001 | 50 |
| | 5 | 5 | 1 | 0.001 | 50 |
| | 5 | 7 | 1 | 0.001 | 50 |
| | 5 | 9 | 1 | 0.001 | 50 |
| | 5 | 11 | 1 | 0.001 | 50 |
| | 5 | 1 | 1 | 0.001 | 500 |
| | 5 | 3 | 1 | 0.001 | 500 |
| | 5 | 5 | 1 | 0.001 | 500 |
| | 5 | 7 | 1 | 0.001 | 500 |
| | 5 | 9 | 1 | 0.001 | 500 |
| 5 | 11 | 1 | 0.001 | 500 | |
| 5 | 1 | 1 | 0.001 | 1000 | |
| 5 | 3 | 1 | 0.001 | 1000 | |
| 5 | 5 | 1 | 0.001 | 1000 | |
| 5 | 7 | 1 | 0.001 | 1000 | |
| 5 | 9 | 1 | 0.001 | 1000 | |
| 5 | 11 | 1 | 0.001 | 1000 | |

Berdasarkan skema observasi tersebut, kita bisa melihat bahwa ada beberapa variabel bebas yang digunakan, yaitu jumlah parameter *input*, jumlah parameter *output*, nilai *learning rate*. Sedangkan untuk variabel terkontrol adalah metode *preprocessing*, jumlah *hidden layer*, dan jumlah *epoch*. Perubahan yang dilakukan atas variabel-variabel terkontrol inilah yang diobservasi selama eksperimen dilakukan dengan melihat nilai MSE yang dihasilkan.

Proses *training* yang dilakukan atas skema observasi tersebut menghasilkan pemetaan nilai MSE, seperti yang ditampilkan dalam Gambar 2. Dapat dilihat bahwa metode *preprocessing* yang digunakan memberikan dampak yang cukup signifikan atas sebaran nilai MSE selama proses *training* berlangsung. Pada metode *preprocessing Standardization* nilai MSE yang dihasilkan relatif lebih tinggi dibandingkan dengan nilai yang dihasilkan oleh metode *preprocessing Min Max Normalization*. MSE tertinggi yang dihasilkan dalam proses *training* dengan *preprocessing Min Max Normalization* berada di bawah 0.35. Sedangkan dengan

menggunakan *preprocessing Standardization* menghasilkan nilai MSE hingga 1.35, yang didapatkan dengan pengaturan nilai *epoch* sebesar 500 *epoch*.



Gambar 2. Grafik MSE atas Experimen yang Dilakukan Berdasarkan Skema Observasi

Jika ditinjau lebih dalam, pemetaan atas sebaran nilai MSE dengan model *preprocessing* MinMax Normalization memiliki sebaran yang lebih stabil. Dalam artian bahwa, meskipun jumlah *hidden layer* menentukan nilai MSE di awal siklus (*epoch*), dan memiliki nilai yang bervariasi. Stabilitas nilai MSE ini bahkan telah didapatkan pada nilai *epoch* di bawah 10. Pada jumlah *epoch* 50, nilai MSE terendah di awal *epoch* dihasilkan oleh arsitektur dengan jumlah *hidden layer* 7. Pada jumlah *epoch* 500, nilai MSE terendah di awal *epoch* dihasilkan oleh arsitektur dengan jumlah *hidden layer* 11. Sementara itu, pada arsitektur dengan jumlah *epoch* 1000, nilai MSE terendah di awal *epoch* ternyata juga dihasilkan oleh jumlah *hidden layer* 11.

Pada model *preprocessing* Min Max Normalization, sebaran nilai MSE yang dihasilkan relatif lebih fluktuatif. Bahkan dengan skema 1000 *epoch*, masih terjadi fluktuasi nilai MSE di setiap siklusnya, meskipun nilai MSE telah dapat ditekan pada siklus awal. Pengaruh *hidden layer* pada model *preprocessing* ini juga terlihat dengan jelas, dengan grafik yang melandai dan mendapat nilai stabilitas pada nilai MSE yang relatif berbeda dan *epoch* yang berbeda. Pada arsitektur dengan jumlah *epoch* 50, nilai MSE terendah pada awal *epoch* dihasilkan oleh arsitektur dengan jumlah *hidden layer* sebanyak 7 *hidden layer*. Pada arsitektur dengan jumlah *epoch* 500, nilai MSE terendah pada awal *epoch* dihasilkan oleh arsitektur dengan jumlah *hidden layer* sebanyak 7 *hidden layer*. Uniknya, pada arsitektur dengan jumlah *epoch* 1000, nilai MSE terendah pada awal *epoch* ternyata juga dihasilkan oleh arsitektur dengan jumlah *hidden layer* sebanyak 7 *hidden layer*. Ada dua hal menarik lainnya yang juga terjadi pada arsitektur ini. Pertama, dapat dilihat bahwa pada arsitektur dengan jumlah *epoch* 500 dan 3 *hidden layer*, nilai MSE melandai di angka yang relatif stabil pada *epoch* awal diangka 0.96, hingga pada jumlah *epoch* di atas 300 nilai MSE ini kembali melandai menyentuh angka stabil pada nilai MSE di bawah 0.95. Kedua, pada arsitektur dengan jumlah *epoch* 1000 dan jumlah *hidden layer* 1, dapat dilihat bahwa nilai MSE yang dihasilkan benar-benar berbeda jika dibandingkan dengan arsitektur lainnya pada jumlah *epoch* yang sama.

Tabel 5. Nilai MSE pada Proses Testing

| PreProcessing | Input | Hidden Layer | Output | Learning Rate | Jumlah Epoch | MSE |
|-----------------------|-------|--------------|--------|---------------|--------------|----------------|
| Min Max Normalization | 5 | 1 | 1 | 0.001 | 50 | 0.03192 |
| | 5 | 3 | 1 | 0.001 | 50 | 0.02995 |
| | 5 | 5 | 1 | 0.001 | 50 | 0.02952 |
| | 5 | 7 | 1 | 0.001 | 50 | 0.02929 |
| | 5 | 9 | 1 | 0.001 | 50 | 0.0287 |
| | 5 | 11 | 1 | 0.001 | 50 | 0.0282 |
| | 5 | 1 | 1 | 0.001 | 500 | 0.03052 |
| | 5 | 3 | 1 | 0.001 | 500 | 0.03226 |
| | 5 | 5 | 1 | 0.001 | 500 | 0.02913 |
| | 5 | 7 | 1 | 0.001 | 500 | 0.02944 |
| | 5 | 9 | 1 | 0.001 | 500 | 0.02962 |
| | 5 | 11 | 1 | 0.001 | 500 | 0.02896 |
| | 5 | 1 | 1 | 0.001 | 1000 | 0.03035 |
| | 5 | 3 | 1 | 0.001 | 1000 | 0.02806 |
| | 5 | 5 | 1 | 0.001 | 1000 | 0.02882 |
| Standardization | 5 | 7 | 1 | 0.001 | 1000 | 0.03159 |
| | 5 | 9 | 1 | 0.001 | 1000 | 0.03166 |
| | 5 | 11 | 1 | 0.001 | 1000 | 0.02833 |
| | 5 | 1 | 1 | 0.001 | 50 | 0.94406 |
| | 5 | 3 | 1 | 0.001 | 50 | 0.94849 |
| | 5 | 5 | 1 | 0.001 | 50 | 0.88741 |

| PreProcessing | Input | Hidden Layer | Output | Learning Rate | Jumlah Epoch | MSE |
|---------------|-------|--------------|--------|---------------|--------------|----------------|
| | 5 | 7 | 1 | 0.001 | 50 | 0.98593 |
| | 5 | 9 | 1 | 0.001 | 50 | 0.91117 |
| | 5 | 11 | 1 | 0.001 | 50 | 0.87576 |
| | 5 | 1 | 1 | 0.001 | 500 | 0.94202 |
| | 5 | 3 | 1 | 0.001 | 500 | 0.94198 |
| | 5 | 5 | 1 | 0.001 | 500 | 0.87646 |
| | 5 | 7 | 1 | 0.001 | 500 | 0.96748 |
| | 5 | 9 | 1 | 0.001 | 500 | 0.91826 |
| | 5 | 11 | 1 | 0.001 | 500 | 0.91379 |
| | 5 | 1 | 1 | 0.001 | 1000 | 1.02369 |
| | 5 | 3 | 1 | 0.001 | 1000 | 0.9214 |
| | 5 | 5 | 1 | 0.001 | 1000 | 0.93582 |
| | 5 | 7 | 1 | 0.001 | 1000 | 0.96793 |
| | 5 | 9 | 1 | 0.001 | 1000 | 0.9487 |
| | 5 | 11 | 1 | 0.001 | 1000 | 0.91738 |

Jika ditinjau dari sebaran nilai MSE yang diperoleh berdasarkan proses *testing*, sebagaimana yang ditunjukkan pada Tabel 5, ternyata nilai yang dihasilkan tidak sepenuhnya berbanding lurus dengan nilai MSE yang dihasilkan pada proses *training*. Arsitektur pada proses *testing* yang nilai MSE-nya berkorelasi dengan arsitektur pada proses *training* adalah *Backpropagation Neural Network* dengan 11 *hidden layer* dan 500 *epoch*. Sementara nilai MSE terendah atas seluruh variabel kontrol yang diobservasi pada proses *testing*, baik perbedaan metode *preprocessing* yang digunakan, jumlah *hidden layer*, dan juga jumlah *epoch* yang digunakan, ternyata dimiliki oleh arsitektur yang menggunakan metode *Preprocessing Min Max Normalization* dengan 11 *hidden layer* dan 50 *epoch*, dengan nilai MSE sebesar 0.02896.

4. Simpulan

Berdasarkan observasi yang telah dilakukan selama proses eksperimen berlangsung, didapatkan beberapa kesimpulan yang berkorelasi dengan data yang didapatkan sebagai *output* eksperimen atas variabel kontrol yang telah diobservasi. Metode *preprocessing* yang digunakan ternyata memang memiliki pengaruh pada proses *training* dan *testing*. *Min Max Normalization* menghasilkan *output* dengan nilai MSE yang relatif lebih rendah dan lebih stabil. Nilai MSE yang rendah berarti bahwa *Backpropagation Neural Network* memiliki tingkat akurasi yang relatif tinggi. Nilai MSE yang relatif rendah dihasilkan oleh arsitektur dengan jumlah *hidden layer* 5 atau lebih tinggi. Sedangkan jumlah *epoch* memiliki kondisi yang agak berbeda. Pada arsitektur dengan model *preprocessing Min Max Normalization*, dapat dilihat bahwa tingginya nilai *epoch*, relatif mempengaruhi turunnya nilai MSE yang dihasilkan. Sementara hal ini tidak terjadi pada arsitektur dengan model *preprocessing Standardization*.

Selanjutnya, pengembangan dan observasi yang dapat dilakukan dan diteliti adalah tentang bagaimana pengaruh pengacakan data terhadap proses *training* dan *testing*. Karena dalam penelitian ini, *dataset* yang digunakan memiliki unsur *time series*, jadi proses pembagian atas data *training* dan *testing* terurut berdasarkan waktu. Skema observasi serupa dapat digunakan juga untuk menguji keandalan *Backpropagation Neural Network* terhadap algoritma peramalan lain dengan arsitektur yang relatif serupa. Selanjutnya, karena *dataset* yang digunakan di dalam penelitian ini adalah gabungan data harian dan data bulanan dengan varian data yang relatif homogen di beberapa parameter input, maka kegiatan observasi juga dapat dilakukan dengan menggunakan *dataset* harian dengan varian data yang lebih heterogen sebagai data latih dan data uji.

Daftar Rujukan

- Astuti, P. B., & Mahardhika, A. S. (2020). COVID-19: How Does It Impact to the Indonesian Economy? *Jurnal Inovasi Ekonomi*, 5(02). Retrieved 10 February 2023 from <https://doi.org/10.22219/JIKO.V5I02.11751>.
- Badan Pusat Statistik. (n.d.). Retrieved 10 February 2023, from <https://www.bps.go.id/subject/13/keuangan.html#subjekViewTab5>.
- Data Inflasi. (n.d.). Retrieved 10 February 2023, from <https://www.bi.go.id/id/statistik/indikator/data-inflasi.aspx>.
- Guan, H., Dai, Z., Zhao, A., & He, J. (2018). A Novel Stock Forecasting Model based on High-Order-Fuzzy-Fluctuation Trends and Back Propagation Neural Network. *PLOS ONE*, 13(2), e0192366. Retrieved 10 February 2023 from <https://doi.org/10.1371/JOURNAL.PONE.0192366>.
- Habir, M. T., & Wardana, W. (2020). COVID-19's Impact on Indonesia's Economy and Financial Markets. Retrieved 10 February 2023 from <https://think-asia.org/handle/11540/12952>.
- Herliansyah, Y., Nugroho, L., Ardilla, D., & Putra, Y. (2020). The Determinants of Micro, Small and Medium Entrepreneur (MSME) Become Customer of Islamic Banks (Religion, Religiosity and Location of Islamic Banks). Retrieved 10 February 2023 from <https://doi.org/10.4108/EAI.26-3-2019.2290775>.
- Nilai Tukar Mata Uang Asing Terhadap Rupiah | Satu Data Perdagangan. (n.d.). Retrieved 10 February 2023, from <https://satudata.kemendag.go.id/data-informasi/perdagangan-dalam-negeri/nilai-tukar>.
- Peta Harga Barang Pokok | Satu Data Perdagangan. (n.d.). Retrieved 10 February 2023, from <https://satudata.kemendag.go.id/data-informasi/harga-komoditas/peta-harga-barang-pokok>.
- Ping, F. F., & Fei, F. X. (2013). Multivariant Forecasting Mode of Guangdong Province Port throughput with Genetic Algorithms and Back Propagation Neural Network. *Procedia - Social and Behavioral Sciences*, 96, 1165–1174. Retrieved 10 February 2023 from <https://doi.org/10.1016/j.SBSPRO.2013.08.133>.
- Produk Domestik Bruto (PDB) | Satu Data Perdagangan. (n.d.). Retrieved 10 February 2023, from <https://satudata.kemendag.go.id/data-informasi/perdagangan-dalam-negeri/produk-domestik-bruto>.
- Raja Pramudita, M., Ruslina, E., Dewi,;, Gustini, R., & Fakultas, ; (2022). Resesi Ekonomi dan Implikasinya dari Perspektif Hukum Dagang Pasca Pandemi Tahun 2023. *Nusantara: Jurnal Pendidikan, Seni, Sains Dan Sosial Humaniora*, 1(01), 1–1. Retrieved 10 February 2023 from <https://doi.org/10.11111/nusantara.xxxxxxx>
- Rayfinando, Y., Hutagaol, T., Keuangan, P., Stan, N., Putra, R., Sinurat, P., ... Korespodensi, S. A. (2022). Strategi Penguatan Keuangan Negara Dalam Menghadapi Ancaman Resesi Global 2023 Melalui Green Economy. *Jurnal Pajak Dan Keuangan Negara (PKN)*, 4(1S), 378–385. Retrieved 10 February 2023 from <https://doi.org/10.31092/JPKN.V4I1S.1911>.
- Siregar, S. P., Wanto, A., Tunas, S., & Pematangsiantar, B. (2017). Analysis of Artificial Neural Network Accuracy Using Backpropagation Algorithm in Predicting Process (Forecasting). *IJISTECH (International Journal of Information System and Technology)*, 1(1), 34–42. Retrieved 10 February 2023 from <https://doi.org/10.30645/IJISTECH.V1I1.4>.
- Susilawati, S., Falefi, R., & Purwoko, A. (2020). Impact of COVID-19's Pandemic on the Economy of Indonesia. *Budapest International Research and Critics Institute-Journal (BIRCI-Journal)*, 3(2), 1147–1156. Retrieved 10 February 2023 from <https://doi.org/10.33258/BIRCI.V3I2.954>.
- Tarif Adjustment. (n.d.). Retrieved 10 February 2023, from <https://web.pln.co.id/pelanggan/tarif-tenaga-listrik/tariff-adjustment>.