



Penerapan Artificial Neural Network Backpropagation untuk Meramalkan Nilai Ekspor Indonesia

Adhiyatma Nugraha¹, Yusep Superman², Anindya Apriliyanti Pravitarsari³
Universitas Padjadjaran^{1,2,3}
Adhinugraha12@gmail.com

Abstrak. Republik Indonesia (RI) adalah salah satu negara berkembang dengan kekayaan sumber daya alam yang melimpah. Dalam pemanfaatan sumber daya alam tersebut, RI berperan dalam pengelolaan potensi tersebut dan sebagian bisa ditujukan untuk kegiatan ekspor. Ekspor adalah sebuah proses pengiriman barang atau komoditas dari satu negara ke negara yang lainnya. Dengan adanya kegiatan ekspor, maka akan memberikan manfaat berupa penghasil devisa yang dapat meningkatkan pendapatan negara. Pendapatan RI dari ekspor mencakup 42,1% total pendapatan negara. Dengan demikian kontribusi ekspor dalam pendapatan negara cukup besar. Namun demikian, nilai ekspor dari waktu ke waktu sifatnya tidak pasti. Hal ini akan menyulitkan RI dalam menentukan pendapatan negara yang nantinya dipergunakan untuk perancangan program pembangunan. Untuk membantu mengatasi permasalahan tersebut diperlukan informasi mengenai kinerja ekspor pada masa yang akan datang. Dari ramalan ini pemerintah dapat menentukan kebijakan untuk mengantisipasi gejolak yang akan terjadi. Makalah ini kami tujukan untuk memperoleh ramalan nilai ekspor Indonesia di masa mendatang. Kami menggunakan data bulanan nilai ekspor Indonesia dari tahun 2011-2021. Kami menggunakan *metode artificial neural network* dengan algoritma *backpropagation* untuk mengatasi keterbatasan pada metode peramalan klasik (ARIMA). Arsitektur jaringan optimum yang didapat adalah jaringan (12-6-1) dengan 12 unit pada lapisan *input*, 6 unit pada lapisan tersembunyi, dan 1 unit pada lapisan *output*. Jaringan ini menghasilkan MAPE terkecil pada tahap pengujian (*testing*) sebesar 9,87108. Peramalan nilai ekspor Indonesia dengan menggunakan jaringan tersebut dilakukan sampai dengan 12 periode kedepan. Didapatkan bahwa nilai ekspor Indonesia mengalami nilai yang berfluktuatif, nilai yang paling tinggi terjadi pada bulan september 2021 dan terendah pada bulan april 2022.

Kata kunci: ekspor, peramalan, artificial neural network, backpropagation.

I. PENDAHULUAN

Indonesia adalah salah satu negara berkembang dengan kekayaan sumber daya alam yang melimpah. Dalam pemanfaatan sumber daya alam tersebut, Negara Indonesia memiliki peranan dalam mengelola potensi yang ada untuk perdagangan internasional. Perdagangan Internasional merupakan perdagangan antar atau lintas negara (Tambunan, 2001). Dengan adanya perdagangan internasional, seluruh negara yang ada didunia dapat melakukan perdagangan sumber daya masing-masing dengan tujuan tidak adanya kekurangan ataupun kelebihan sumber daya dimasing-masing negara tersebut dan sebagai penghasil cadangan devisa.


Cadangan devisa merupakan sumber pembiayaan perdagangan internasional yang dikelola oleh Bank Indonesia dan ditetapkan dalam Undang-Undang tentang Bank Indonesia No. 3 Tahun 2004. Cadangan devisa menjadi salah satu indikator yang sangat penting untuk melihat sejauh mana Negara Indonesia mampu melakukan perdagangan internasional (Priadi, 2008). Perdagangan internasional ini dapat berupa kegiatan ekspor.

Ekspor adalah pengiriman barang atau komoditas dari dalam negeri ke luar negeri (Anita, 2017). Dengan dilakukannya kegiatan ekspor di Indonesia maka akan memberikan manfaat yang besar yaitu sebagai penghasil devisa bagi Negara Indonesia. Secara umum barang yang di ekspor oleh Indonesia dikelompokkan menjadi barang sektor migas dan non migas. Barang yang termasuk migas di antaranya bensin, solar, minyak tanah dan gas. Adapun barang yang termasuk non migas diantaranya biji coklat,





biji kopi, teh, buah-buahan, minyak sawit, tekstil dan karet alam. Berikut merupakan grafik nilai Ekspor Indonesia



Gambar 1.1 Grafik Nilai Ekspor Indonesia

Berdasarkan **Gambar 1.1** dapat dilihat bahwa nilai ekspor Indonesia mengalami fluktuasi, di beberapa tahun, nilai ekspor Indonesia mengalami penurunan dikarenakan pandemi Covid-19 khususnya di tahun 2020. Jika kita melihat Nilai ekspor di Indonesia melalui data time series Bank Indonesia selama 10 tahun terakhir, dapat dilihat bahwa nilai ekspor Indonesia mengalami penurunan dari tahun 2011-2016, tahun 2011 sebesar US\$ 16997140 ribu, 2012 sebesar US\$ 15678516 ribu, 2013 sebesar US\$ 15245890 ribu, 2014 sebesar US\$ 14117887 ribu, 2015 sebesar US\$ 12696423 ribu, 2016 sebesar US\$ 10219982 ribu, selanjutnya dari tahun 2017-2019 mengalami kenaikan, 2017 sebesar US\$ 13369264 ribu, 2018 sebesar US\$ 14042640.94 ribu, 2019 sebesar US\$ 14553896.24 ribu dan pada tahun 2020 mengalami penurunan yang sangat tajam dengan nilai sebesar US\$ 10444487.8 ribu. Penentuan target perdagangan ekspor Indonesia semestinya didukung oleh informasi data yang akurat dan hal ini merupakan salah satu upaya yang dapat membantu pihak pemerintah dan Bank Indonesia untuk mengetahui devisa yang akan diperoleh Negara Indonesia, sehingga pemerintah dan Bank Indonesia dapat merumuskan kebijakan untuk melakukan pemulihan ekonomi Indonesia dimasa Pandemi Covid-19.

Maka untuk mengatasi permasalahan tersebut, perlu dilakukannya peramalan terhadap nilai ekspor Indonesia. Namun, data nilai ekspor Indonesia tidak dapat diidentifikasi menggunakan metode ARIMA (*Autoregressive Integrated Moving Average*) karena tidak memenuhi asumsi, diantaranya asumsi homoskedastisitas dan data nilai ekspor Indonesia berfluktuasi secara random sehingga tidak terlihat mengikuti pola tertentu berdasarkan pada **Gambar 1.1**.

II. METODE PENELITIAN

2.1 Data Penelitian

Data yang digunakan pada penelitian ini adalah data sekunder yang diperoleh dari Website resmi Bank Sentral Republik Indonesia (<https://www.bi.go.id/id/statistik/ekonomi-keuangan/seki/Default.aspx>). Variabel yang digunakan pada penelitian ini adalah nilai ekspor Indonesia dari bulan Januari 2011 sampai dengan bulan Mei 2021.


2.2 Peramalan

Peramalan adalah prediksi terhadap sebuah faktor sehingga hasil prediksi tersebut dapat digunakan untuk pengambilan keputusan untuk mencapai tujuan (Makridakis, 1999). Metode peramalan dibagi menjadi dua kategori yaitu kualitatif dan kuantitatif. Dalam kasus nilai ekspor di Indonesia ini peramalan yang digunakan adalah peramalan kuantitatif. Terdapat dua jenis model peramalan kuantitatif yaitu model analisis deret waktu (time series) dan model regresi (Aswi & Sukarna, 2006). Tujuan peramalan adalah memperkirakan peristiwa di waktu yang akan datang atas dasar pola-pola di waktu yang lalu.

2.3 Feed Forward Neural Network (FFNN)

Data *Feed Forward Neural Network* (FFNN) adalah salah satu model *neural network* yang sering digunakan dalam berbagai bidang. Model ini melakukan pergerakan hanya dalam satu arah maju dari *input layer* hingga *output layer* (Zell, 1994). Terdapat beberapa arsitektur dalam *Feed Forward Neural Network* diantaranya *Single Layer Perception* (SLP) dan *Multi Layer Perception* (MLP).





Gambar 2.1 Arsitektur *Single Layer Perception*

Berdasarkan Gambar 2.1 dapat dilihat bahwa arsitektur ini terdiri dari *input layer* dan langsung terhubung ke *output layer*. Terdapat X neuron dalam lapisan input dan Z neuron dalam lapisan output sedangkan w_{ik} adalah bobot yang menghubungkan lapisan input dan output. NN dengan *single layer* memiliki keterbatasan dalam pengenalan pola dan dapat ditanggulangi dengan menambah lapisan tersembunyi (*hidden layer*) di antara lapisan input dan output.

2.4 Artificial Neural Network Backpropagation


Data Artificial Neural Network (ANN) adalah jaringan syaraf tiruan yang dikembangkan sebagai generalisasi model matematika dari jaringan syaraf manusia (Fauset, 1994). Metode Artificial Neural network ini memiliki kemampuan untuk mempelajari dan mengadaptasi situasi baru dengan mengingat pola data masa lalu bahkan ketika terjadi noise (David, 2012).

Jaringan syaraf tiruan memiliki sekumpulan unit pemrosesan yang disebut sebagai “neuron” yang tersusun dalam lapisan-lapisan tertentu dan saling terhubung melalui asosiasi bobot. Terdapat tiga jenis lapisan pada Artificial Neural Network, yaitu lapisan input yang berfungsi menerima gambaran suatu masalah, lapisan output yang berfungsi mengeluarkan penyelesaian masalah dan lapisan hidden yang terletak diantara lapisan input dan lapisan output.

Metode Artificial Neural Network memiliki tiga karakteristik yaitu pola koneksi (disebut arsitektur jaringan), metode untuk menentukan bobot pada koneksi disebut (training, learning, atau algoritma), dan fungsi aktivasi yang berfungsi sebagai pembangkit sinyal pada neuron (Fausett, 1994).

Penerapan metode Artificial Neural Network pada penelitian ini bertujuan untuk mengatasi keterbatasan pada metode peramalan klasik seperti ARIMA (Autoregressive Integrated Moving Average), diantaranya data heteroskedastisitas karena metode ini tidak memiliki asumsi apapun. Selain itu, karena metode Artificial Neural Network sangat baik dalam peramalan jangka panjang. Metode ini juga merupakan salah satu metode peramalan yang dapat digunakan jika data yang ada tidak stasioner (Munarsih, 2011). Sehingga penerapan metode Artificial Neural Network tepat digunakan untuk peramalan nilai ekspor Indonesia.

Algoritma *Backpropagation* merupakan algoritma dengan banyak lapisan (*multi layer*) yang menggunakan proses pembelajaran terawasi (Kusumadewi, 2003). Terdapat tiga tahapan utama dari algoritma *backpropagation* yaitu tahap *feedforward* pada pola pelatihan *input* tahap perhitungan dan *backpropagation* dari nilai *error*, dan terakhir penyesuaian bobot (Fausset, 1994).



Gambar 2.2 Arsitektur *Multi Layer Perception*





Berdasarkan **Gambar 2.2** dapat dilihat bahwa arsitektur ini terdiri dari *input layer*, *hidden layer* dan *output layer*. Terdapat X neuron dalam lapisan input, Y neuron dalam lapisan hidden dan Z neuron dalam lapisan output. Algoritma ini disebut dengan Backpropagation karena saat jaringan diberikan *input* sebagai pola pelatihan maka *input* tersebut diteruskan ke lapisan *hidden* dan lapisan *output*, namun juga *output* tidak sesuai maka *output* tersebut akan kembali lagi ke lapisan *hidden*. Selain itu algoritma *backpropagation* merupakan jaringan syaraf yang kuat dan berkinerja relatif baik yang dapat diterapkan dengan mudah di berbagai domain masalah (Jeatrakul & Wong, 2009).

III. HASIL DAN PEMBAHASAN

3.1 Artificial Neural Network Backpropagation

Metode peramalan pada penelitian ini akan menggunakan *Artificial Neural Network* dengan algoritma *backpropagation* dimana metode ini memiliki tiga lapisan yaitu *input layer*, *hidden layer* dan *output layer*. *Input Layer* mempunyai fungsi sebagai penghubung jaringan ke sumber data. Didalam *input layer* ini terdapat unit-unit yang berfungsi menerima pola dari luar yang menggambarkan suatu permasalahan. Selanjutnya terdapat *output layer* yang terdapat unit-unit yang berfungsi menghasilkan solusi hasil peramalan. Berikut langkah-langkah penerapan metode *Artificial Neural Network Backpropagation* :

Langkah 0. Inisialisasi bobot dengan nilai *random* sekecil mungkin.

Langkah 1. Selama kondisi stop belum dilalui maka lakukan langkah 2-9.

Langkah 2. Untuk setiap data *training*, lakukan langkah 3-8.

Fase I: Perambatan Maju (Feedforward)

Langkah 3. Setiap unit *input* ($X_i, i = 1, \dots, n$) menerima sinyal *input* x_i dan meneruskan ke semua unit pada lapisan selanjutnya yaitu lapisan tersembunyi.

Langkah 4. Setiap unit tersembunyi ($Z_j, j = 1, \dots, p$) menjumlahkan sinyal input terbobot dengan perhitungan,

$$z_{in_j} = v_{oj} + \sum_{i=1}^n x_i v_{ij} \quad (3.1)$$

Gunakan fungsi aktivasi untuk menghitung sinyal output,

$$z_j = f(z_{in_j}) \quad (3.2)$$

Sinyal akan dikirimkan ke semua unit pada lapisan selanjutnya (lapisan *output*), langkah ini dilakukan sebanyak jumlah lapisan tersembunyi

Langkah 5. Setiap unit output ($Y_k, k = 1, \dots, m$) menjumlahkan sinyal *input* terbobot dengan perhitungan,

$$y_{in_k} = w_{ok} + \sum_{j=1}^p z_j w_{jk} \quad (3.3)$$

Gunakan fungsi aktivasi untuk menghitung sinyal *output*,

$$y_k = f(y_{in_k}) \quad (3.4)$$

Fase II: Propagasi Mundur (Backpropagation)

Langkah 6. Setiap unit *output* ($Y_k, k = 1, \dots, m$) menerima pola target sesuai dengan pola pelatihan input, hitung informasi *error*,

$$\delta_k = (t_k - y_k) f'(y_{in_k}) \quad (3.5)$$

Hitung koreksi bobot (selanjutnya akan digunakan untuk memperbarui w_{jk} dengan laju percepatan α ,

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (3.6)$$

Hitung koreksi bias (selanjutnya akan digunakan untuk memperbarui w_{ok} ,

$$\Delta w_{ok} = \alpha \delta_k \quad (3.7)$$

Kirim δ_k ke unit-unit pada lapisan sebelumnya.

Langkah 7. Setiap unit tersembunyi ($Z_j, j = 1, \dots, p$) jumlahkan delta *input* (dari unit pada lapisan yang berada setelahnya),





$$\delta_{in_j} = \sum_{k=1}^m \delta_k w_{jk} \quad (3.8)$$

Kalikan nilai ini dengan turunan fungsi aktivasi untuk menghitung informasi *error*,

$$\delta_j = \delta_{in_j} f'(z_{in_j}) \quad (3.9)$$

Hitung koreksi bobot (selanjutnya akan digunakan untuk memperbaiki v_{ij}),

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (3.10)$$

Dan hitung koreksi bias (selanjutnya akan digunakan untuk memperbaiki v_{oj})

$$\Delta v_{oj} = \alpha \delta_j \quad (3.11)$$

Tahap perubahan bobot dan bias

Langkah 8. Setiap unit *output* ($Y_k, k = 1, \dots, m$) melakukan perbaikan bias dan bobot ($j = 0, \dots, p$):

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (3.12)$$

Setiap unit tersembunyi ($Z_j, j = 1, \dots, p$) melakukan perbaikan bias dan bobot ($i = 0, \dots, n$):

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (3.13)$$

Langkah 9. Kondisi stop

3.2 Perancangan Sistem

3.2.1 Pembagian Data

Setelah didapatkan data nilai ekspor Indonesia, selanjutnya data tersebut dibagi menjadi dua bagian yaitu data training (pelatihan) dan testing (pengujian). Data training adalah data yang digunakan ketika proses training untuk melakukan proses mengenali pola data dan pembelajaran data. Sedangkan, data testing adalah data yang digunakan ketika proses testing untuk melakukan proses pengujian dari hasil pengenalan dan pembelajaran data pada proses training. Hal ini bertujuan untuk mendapatkan data yang cukup untuk proses pelatihan dan pengujian sehingga didapatkan hasil yang optimal. Data training digunakan untuk pembentukan model, sedangkan data testing digunakan sebagai pengujian untuk pemilihan ramalan terbaik. Proporsi pembagian data pelatihan dan pengujian tidak tergantung pada suatu aturan khusus. Namun pada umumnya 20% untuk data pengujian dan 80% untuk data pelatihan (Hyndman & Athanasopoulos, 2018).

3.2.2 Penentuan Arsitektur Jaringan

Penelitian ini akan menggunakan arsitektur *multilayer perceptron* (MLP) yang memiliki tiga jenis lapisan didalamnya. Satu lapisan *input* untuk menerima informasi eksternal, satu lapisan *output* untuk mengeluarkan solusi dari permasalahan yang diperoleh, serta satu atau lebih lapisan tersembunyi yang terletak diantara lapisan *input* dan *output*.

Lapisan input terdiri dari sejumlah unit yang akan merepresentasikan keadaan masalah yang diterima dari luar pada proses pelatihan jaringan, jumlah *neuron input* dalam analisis data deret waktu univariat ditentukan oleh interval waktu berdasarkan jenis data yang digunakan. Untuk 12 *neuron input* digunakan ketika seri waktu bulanan, 3 *neuron input* digunakan ketika seri waktu triwulan, dan sebagainya (Bakhari et.al, 2004)

Lapisan tersembunyi dapat berjumlah satu atau lebih pada arsitektur jaringan *Multilayer Perceptron*. Tetapi, suatu jaringan tidak membutuhkan lebih dari dua lapisan tersembunyi untuk memecahkan masalah, termasuk pada masalah peramalan yang cukup menggunakan satu lapisan tersembunyi saja (Zhang, 1998), terdapat dua jenis mekanisme dalam metode *trial-and-error* yaitu, *forward approach* (jumlah *neuron* tersembunyi dimulai dari jumlah yang kecil hingga jumlah yang besar dan *backward approach* dimulai dari jumlah *neuron* yang besar dan terus berkurang.

Jumlah unit output pada lapisan output ditentukan dengan melihat masalah yang diteliti. Pada masalah peramalan, jumlah unit output yang digunakan adalah satu unit untuk peramalan satu langkah ke depan (Zhang, Patuwo, & Hu, 1998). Satu unit output tersebut juga dapat digunakan untuk peramalan beberapa langkah ke depan dengan dilakukan secara berulang.






3.2.3 Penentuan Fungsi Aktivasi

Fungsi aktivasi merupakan sebuah operasi dasar yang digunakan dalam sebuah jaringan. Fungsi aktivasi akan menentukan *output* suatu unit (mengubah sinyal *input* menjadi sinyal *output*). Tidak ada aturan khusus dalam memilih fungsi aktivasi yang akan digunakan. Pemilihan fungsi aktivasi akan didasarkan pada permasalahan yang dihadapi serta metode atau algoritma pelatihan yang digunakan dalam melatih sebuah jaringan. Fungsi aktivasi yang digunakan untuk algoritma *backpropagation* harus memiliki beberapa karakteristik yang penting, yaitu bersifat kontinu, *differentiable*, dan merupakan fungsi yang tidak menurun secara monoton (Fausett, 1994).

Salah satu fungsi aktivasi yang paling sering digunakan pada umumnya adalah fungsi sigmoid biner (Fausett, 1994) sehingga fungsi aktivasi yang akan digunakan dalam penelitian ini adalah fungsi sigmoid biner yang telah memenuhi ketiga syarat tersebut.



Gambar 3.1 Fungsi Sigmoid Biner

Berdasarkan Gambar 3.1 dapat dilihat bahwa Fungsi sigmoid biner ini memiliki nilai pada range 0 sampai 1. Dirumuskan sebagai berikut:

$$y = f(x) = \frac{1}{1+e^{-x}} \quad (3.14)$$

dengan,

$$f'(x) = [f(x)][1 - f(x)] \quad (3.15)$$

3.2.4 Normalisasi Data

Normalisasi data dilakukan dengan menggunakan teknik *min-max scaling* yang diterapkan pada data aktual agar dapat masuk ke dalam fungsi aktivasi yang digunakan untuk meminimalkan *error* dan menghasilkan nilai di antara 0 dan 1. Ini dilakukan agar data tersebut masuk ke dalam selang aktivasi yang digunakan. Berikut adalah rumus normalisasi data (Srinivasan, Liew, & Chang, 1994) :

$$X'_i = \left[\frac{(X_i - X_{min})}{X_{max} - X_{min}} \right] (b - a) + a \quad (3.3)$$

Dimana,

X'_i : hasil normalisasi data

X_i : pengamatan asli ke-i

X_{min} : pengamatan bernilai minimum

X_{max} : pengamatan bernilai maksimum

a : nilai interval tertinggi dari normalisasi yang dilakukan

b : nilai interval terendah dari normalisasi yang dilakukan

3.2.5 Proses Pelatihan (*Training*) dan Pengujian (*Testing*)

Proses pelatihan dilakukan terhadap data pelatihan. Tujuan dari proses pelatihan adalah mencari nilai bobot yang optimum untuk memperoleh *error* yang minimum. Model terbaik dari model yang dilatih merupakan model yang memiliki nilai ukuran kesalahan yang terkecil. Proses *training* dan *testing* jaringan dilakukan dengan menggunakan algoritma *backpropagation* dengan fungsi aktivasi *sigmoid*






biner. Proses *training* dan *testing* menggunakan bantuan *syntax* pada *software* R. Proses *training* atau pelatihan akan berhenti ketika jaringan sudah mencapai konvergen dan menghasilkan nilai kesalahan yang kecil. Pemilihan jaringan yang optimum dapat dilihat pada nilai MAPE pengujian dari berbagai *trial and error* yang dilakukan. Pada penelitian ini, peneliti menggunakan *trial and error* untuk beberapa nilai unit tersembunyi.

Unit Tersembunyi	MAPE Testing
2	12.01519
3	10.58715
4	11.01527
5	10.35941
6	9.87108
7	11.73564
8	10.50247
9	10.90037
10	10.33792

Tabel 3.1 Hasil Training dan Testing

Berdasarkan **Tabel 3.1** terlihat bahwa *training* dan *testing* dilakukan pada 9 nilai unit tersembunyi, yaitu 2 unit – 10 unit. Untuk memilih nilai unit tersembunyi yang terbaik dilakukan dengan melihat nilai MAPE paling kecil pada tahap pengujian atau testing.




Gambar 3.2 Arsitektur Jaringan Terpilih

Unit tersembunyi sebanyak 6 unit memberikan nilai MAPE terkecil pada tahap pengujian (testing) sebesar 9,87108 .Maka dapat disimpulkan bahwa jaringan yang paling optimum adalah jaringan dengan 6 unit tersembunyi yang menghasilkan arsitektur jaringan (12-6-1) berdasarkan **Gambar 3.2**.





Jaringan optimum yang diperoleh yaitu jaringan (12-6-1) diterapkan pada seluruh data nilai ekspor Indonesia untuk dibandingkan nilai prediksi dengan nilai aktualnya. Plot dari perbandingan tersebut adalah sebagai berikut.



Gambar 3.3 Plot Hasil Pengenalan Pola data nilai ekspor Indonesia

Berdasarkan **Gambar 3.3** dapat dilihat bahwa plot tersebut menunjukkan nilai ekspor Indonesia yang dihasilkan oleh jaringan (12-6-1) telah mengikuti data aktual dari seluruh data nilai ekspor Indonesia. Artinya, jaringan tersebut sudah mampu mengakomodasi nilai ekspor yang tinggi serta dapat meramalkan nilai ekspor yang mendekati nilai aktualnya.

3.3 Peramalan

Setelah tahap *training* dan *testing* selesai dan diperoleh jaringan optimum, dapat dilakukan peramalan nilai ekspor Indonesia menggunakan jaringan tersebut untuk periode Juni 2021 – Mei 2022 2021. Jaringan optimum yang didapat adalah jaringan (12-6-1) atau jaringan dengan satu lapisan *input* dengan 12 unit didalamnya, 1 lapisan tersembunyi dengan 6 unit didalamnya, serta 1 lapisan *output* dengan 1 unit didalamnya. Peramalan dilakukan menggunakan seluruh data nilai Ekspor Indonesia. Hasil peramalannya adalah sebagai berikut:

Periode	Nilai Ekspor (Ribu USD)
Juni 2021	14764837
Juli 2021	15579192
Agustus 2021	15387870
September 2021	15822386
Oktober 2021	15497772
November 2021	15401483
Desember 2021	14941752
Januari 2022	14840802
Febrari 2022	14373671
Maret 2022	14795439
April 2022	13407677
Mei 2022	14265477





IV. KESIMPULAN

Berdasarkan analisis yang telah dilakukan pada penelitian ini, maka dapat diambil kesimpulan bahwa *Artificial Neural Network* merupakan suatu metode peramalan yang digunakan untuk meramalkan nilai Ekspor Indonesia. Algoritma yang digunakan adalah algoritma *Backpropagation* dengan fungsi aktivasi *Sigmoid Biner*. Metode ini mampu mengakomodasi karakteristik data nilai ekspor Indonesia, yaitu dapat mengikuti pola acak dari data nilai ekspor Indonesia. Arsitektur jaringan optimum yang didapat adalah jaringan (12-6-1) dengan 12 unit pada lapisan *input*, 6 unit pada lapisan tersembunyi, dan 1 unit pada lapisan *output*. Jaringan ini menghasilkan MAPE terkecil pada tahap pengujian (testing) sebesar 9,87108. Parameter yang digunakan pada penelitian ini adalah *learning rate* yang ditentukan sebesar 0,01 dan *epoch* sebanyak 100000. Berdasarkan jaringan terbaik yang didapatkan tersebut, selanjutnya dilakukan peramalan selama 12 periode ke depan.

DAFTAR PUSTAKA

- [1] Anike Mmarleni dkk, (2012). "Pengembangan Sistem Jaringan Syaraf Tiruan Dalam Memprediksi Jumlah Dokter Keluarga Menggunakan Backpropagation". Seminar Nasional Teknologi dan Komunikasi (SENTIKA), Yogyakarta, 10 Maret 2012.
- [2] Cigizoglu, Hikmet. 2005. Application of Generalized Regression Neural Network to Intermittent Flow Forecasting and Estimation. *Journal of Hydrologic Engineering*, vol.10, hal 339.
- [3] D.A Bong Joseph A, Application of Neural Network in User Authentication for Smart Home System.: World Academy of Science, Engineering and Technology 53., 2009.
- [4] Fromm, G. (1978). Comments on "An Overview of the Objectives and Framework. *Seasonal Analysis of Economic*, 3, 26-29.
- [5] Makridakis, 1998. "International Journal of Forecasting". Halaman 519.
- [6] Makridakis, S. (1999). *Metode dan Aplikasi Peramalan*. (I. H. Suminto, Penerj.) Jakarta: Binarupa Aksara.
- [7] Panchal, F. S., & Panchal, M. (2014). Review on Methods of Selecting Number of Hidden Nodes in Artificial Neural Network. *International Journal of Computer Science and Mobile Computing*, 3(11), 455-464.
- [8] Suhartono, D. (2012). *Dasar Pemahaman Neural Network*. Dipetik July 2021, dari School of Computer Science Binus University: <https://socs.binus.ac.id/2012/07/26/konsep-neural-network/>
- [9] Sivanandam S N, *Introduction to Artificial Neural Network*. New Delhi: Vikas Publication House, 2018.

