

DESIGN OF EXPERIMENT PADA ARTIFICIAL NEURAL NETWORK UNTUK MEMPREDIKSI KURS TUKAR MATA UANG IDR/USD

Rizka Britania*

Departemen Teknik Industri, Fakultas Teknik, Universitas Bina Nusantara,
Jl. K. H. Syahdan No 9, Kemanggis, Palmerah, Jakarta 11480, Indonesia

(Received: June 28, 2022/Accepted: December 5, 2022)

Abstrak

Prediksi kurs tukar mata uang memiliki peranan penting dalam bisnis, salah satunya dalam hal internasional purchasing. Terdapat beberapa metode yang digunakan dalam melakukan forecasting mata uang, salah satunya adalah Artificial Neural Network (ANN). Berdasarkan beberapa penelitian terdahulu, ANN terbukti superior dibandingkan metode forecasting lainnya dalam memprediksi kurs tukar mata uang. Salah satu kelemahan ANN adalah tidak adanya setting parameter yang baku untuk digunakan, sehingga setting parameter yang berbeda dapat memberikan hasil akurasi yang berbeda. Penelitian ini bertujuan menentukan dua nilai parameter yang memiliki pengaruh signifikan, yaitu jumlah input node dan jumlah hidden node melalui metode design of experiment dalam memprediksi kurs tukar mata uang IDR/USD. Bobot awal dan bias pada replikasi yang memberikan performansi lebih baik dari replikasi sebelumnya disimpan untuk selanjutnya digunakan dalam membangkitkan forecast pada periode selanjutnya. Hasil penelitian menunjukkan bahwa delapan input nodes dan empat hidden nodes memberikan akurasi terbaik yang ditandai dengan nilai MSE test terendah. Selain itu, berdasarkan grafik perilaku MSE test dari setiap arsitektur jaringan yang terbentuk, dapat disimpulkan bahwa dalam memprediksi kurs tukar mata uang IDR/USD, jumlah hidden nodes bersifat lebih sensitif dibanding jumlah input nodes.

Kata kunci: Artificial Neural Network; design of experiment; forecast; kurs tukar mata uang

Abstract

Design of Experiment in Artificial Neural Network to Forecast Foreign Exchange Rate IDR/USD]. Forecasting foreign exchange rate plays a significant role in business, for example in international purchasing. There are several methods used in forecasting foreign exchange rates, one of them is the Artificial Neural Network (ANN). Based on several earlier literatures, ANN has been proven as a superior method in forecasting foreign exchange rate compared to other methods. However, ANN has several weaknesses, for example, there is no standard parameters setting used in ANN, thus different parameters setting could lead to different accuracy. This research aims to determine two crucial parameters that give significant impact to the ANN model built; the number of input nodes and the number of hidden nodes, through the design of an experiment to forecast the IDR/USD exchange rate. Initial weights and bias in replication that give better performance than earlier replication are stored and used to forecast the data for next periods as needed. The result of this research shows that eight input nodes and four hidden nodes give the best accuracy to forecast IDR/USD exchange rate which is proven by the lowest MSE test score. Moreover, based on the MSE test behavior graph, the number of hidden nodes is more sensitive than the number of input nodes in forecasting IDR/USD exchange rate.

Keywords: Artificial Neural Network; design of experiment; forecast; foreign exchange rate

1. Pendahuluan

Kurs tukar mata uang menunjukkan nilai mata uang suatu negara yang dinyatakan dalam mata uang negara lain. Fluktuasi pada kurs tukar mata uang memiliki pengaruh langsung terhadap perekonomian suatu negara. Terdapat beberapa hal terkait

perekonomian yang memperoleh pengaruh langsung dari fluktuasi kurs tukar, yaitu tingkat konsumsi suatu negara, ekspor, harga produk, produktivitas, dan kondisi pariwisata (Zhao, 2020).

Ekspor merupakan kegiatan perekonomian negara yang paling mendapat pengaruh dari fluktuasi kurs tukar mata uang. Jika mata uang suatu negara menguat, akan terjadi penurunan ekspor. (Thorbecke & Kato, 2012) membuktikan bahwa ekspor di negara Jepang berkurang sekitar 30% saat terjadi penguatan

*Penulis Korespondensi

E-mail: rizka.britania@binus.ac.id

Yen sebesar 30%. Selain meningkatkan ekspor, pelemahan mata uang juga dapat meningkatkan konsumsi produk domestik sebagai akibat dari mahalnya produk-produk impor. Peningkatan permintaan produk untuk konsumsi domestik dan ekspor tentunya akan meningkatkan permintaan produksi dalam negeri yang mendorong terjadinya peningkatan produktivitas. Selain itu, kondisi pariwisata juga dapat mempengaruhi perekonomian suatu negara. Pelemahan nilai mata uang akan mendorong banyaknya turis asing yang masuk dan menguntungkan bagi negara karena meningkatnya devisa yang masuk. Hal ini sesuai dengan penelitian yang dilakukan oleh (Tung, 2019) dengan studi kasus di Vietnam dan (Nizar, 2012) dengan studi kasus di Indonesia.

Dapat dilihat bahwa kurs tukar mata uang memiliki peranan penting bagi perekonomian suatu negara. Jika ditinjau dari sisi produsen dalam negeri, adanya fluktuasi pada kurs tukar mata uang dapat memberikan kesulitan dalam pengambilan beberapa keputusan penting perusahaan baik itu *supplier*, distributor, maupun penjual. Kemampuan untuk memiliki prediksi kurs yang akurat dapat menguntungkan bagi perusahaan karena dapat membantu dalam membuat keputusan sebaik mungkin.

Salah satu contoh keputusan yang dipengaruhi oleh fluktuasi kurs tukar mata uang adalah keputusan terkait pembelian bahan baku yang berasal dari luar negeri. Pada tanggal 1 April 2015, Bank Indonesia (BI) mengeluarkan kebijakan dalam Peraturan BI No. 17/3/PBI/2015 yang menyatakan bahwa setiap transaksi di wilayah Indonesia wajib menggunakan mata uang Rupiah. Hal ini tentunya menjadi tantangan seperti pada *international purchasing* karena harga bahan baku dinyatakan dalam mata uang negara lain, dan dibayarkan sesuai dengan kurs yang berlaku pada hari pembelian. Sifat kurs tukar mata uang yang fluktuatif memberikan tantangan dalam menentukan kapan waktu pembelian yang optimal. Oleh karena itu diperlukan metode yang dapat memprediksi kurs tukar mata uang yang memberikan *error* seminimal mungkin untuk mengoptimalkan transaksi.

Secara garis besar, metode prediksi kurs tukar mata uang dapat dibedakan menjadi dua; *technical model* dan *economic based model*. Inti dari *technical model* dalam prediksi kurs tukar mata uang adalah untuk menemukan *trend* yang ada dalam *time series data* dan mengasumsikan bahwa *trend* tersebut akan berulang lagi di masa depan. Di sisi lain, inti dari prediksi kurs tukar mata uang menggunakan pendekatan *economic* adalah mencoba menemukan hubungan fungsional antara beberapa variabel independen seperti tingkat suku bunga dan GDP, terhadap variabel dependen (nilai kurs).

Berdasarkan penelitian yang telah ada, kurs tukar mata uang masih dinyatakan sebagai hal yang sulit untuk diprediksi, (Galeshchuk, 2016). Kecenderungan atas penilaian ini berawal dari publikasi (Meese & Rogoff, 1983) dalam (Galeshchuk, 2016) yang menyimpulkan bahwa tidak ada model *economic* yang lebih baik dari metode *simple random walk* untuk memprediksi kurs tukar mata uang. Prediksi

kurs mata uang bukanlah hal yang mudah terkait banyaknya faktor-faktor yang sulit diprediksi di dalamnya dan adanya hubungan nonlinear pada variabel-variabel yang terlibat. Oleh karena itu, untuk memperoleh performansi hasil prediksi yang baik perlu mempertimbangkan sifat nonlinearitas model. Salah satu metode yang dapat mempertimbangkan hal tersebut adalah *Artificial Neural Network* (ANN).

Beberapa penelitian terdahulu telah membuktikan bahwa ANN dapat memberikan hasil prediksi yang lebih baik dibanding metode lainnya. (Panda & Narasimhan, 2007) menggunakan ANN untuk memprediksi kurs tukar INR/USD dan hasilnya adalah ANN memiliki performa lebih baik dibanding model autoregressive dan *random walk*. (Ye, 2012) menggunakan ANN untuk memprediksi kurs tukar RMB/USD dan memperoleh hasil *forecast* yang cukup akurat dan efisien, serta memproyeksi nilai RMB akan meningkat di masa mendatang. (Dunis et al., 2012) menggunakan data harian selama 10 tahun untuk mengevaluasi apakah ANN masih superior dibanding metode lainnya untuk memprediksi EUR/USD, dan hasilnya adalah ANN memberikan hasil yang lebih baik dibanding ARMA dan *random walk*.

Beberapa penelitian juga menggabungkan ANN dengan metode lain untuk berbagai tujuan yang berkaitan dengan prediksi kurs tukar mata uang. (Nag & Mitra, 2002) menggunakan ANN dan *Genetic Algorithm* dalam memprediksi tiga kurs tukar mata uang (DEM/USD, YEN/USD, dan USD/GBP). Hasilnya adalah model yang dibuat memiliki performa lebih baik dibanding model statistik nonlinear ARCH. (Meng & Sun, 2013) menyatakan bahwa sebagian besar peneliti hanya berfokus pada akurasi hasil *forecast*, sehingga dibuatlah *trading rules* berdasarkan hasil *forecast* kurs tukar mata uang yang dilakukannya dengan metode ANN. (Thakur et al., 2016) menggunakan data Januari 2000 hingga Desember 2012 untuk memprediksi inflasi di India. Hasilnya adalah model ANN tersebut memberikan prediksi yang akurat. (Chen & Narala, 2017) menggunakan ANN untuk memprediksi kurs tukar USD/INR selama masa inflasi (Januari 2001 hingga Desember 2014), dan menggunakan model tersebut untuk memprediksi kurs tukar di tahun 2015. (Jena et al., 2015) menggunakan *Knowledge Guided* ANN yang terdiri dari LMS dan FLANN untuk memprediksi kurs tukar USD/GBP dan USD/INR. Hasilnya adalah KGANN memberikan hasil lebih baik dibanding LMS dan FLANN. (Rout, 2013) menggunakan *Recurrent* FLANN untuk memprediksi USD/INR, USD/GBP, dan USD/JPY. Hasilnya adalah model tersebut memberikan prediksi lebih baik dibanding LMS dan FLANN.

Dari beberapa penelitian yang disebutkan di atas, dapat dilihat bahwa ANN merupakan metode yang dapat memberikan hasil prediksi yang baik, bahkan jika dibandingkan dengan metode lainnya. Salah satu tantangan dalam mengaplikasikan ANN adalah belum adanya konfigurasi untuk parameter-parameter yang baku untuk digunakan di dalamnya, sehingga seringkali penggunaan parameter yang berbeda akan memberikan hasil yang berbeda. Terdapat beberapa penelitian terdahulu yang mengkaji besarnya pengaruh

Tabel 1. Perbandingan *Setting* Parameter pada Penelitian (Ye, 2012) dan (Zhang et al., 1998)

Faktor	Penelitian Ye (Ye, 2012)	Penelitian (Zhang et al., 1998)
Horizon	Singkat (tiga <i>step</i>)	Singkat (1-3 <i>step</i>) Menengah (4-8 <i>step</i>)
Pembagian set data	3	≥ 2
Ukuran <i>training set</i>	4 tahun (2005-2009)	2 tahun
<i>Control strategy</i>	<i>Feedforward</i>	<i>Feedforward</i>
Algoritma <i>training</i>	<i>Backpropagation</i>	<i>Backpropagation</i>
Fungsi aktivasi pada <i>hidden layer</i>	<i>Tangent Sigmoid</i>	<i>sigmoidal</i>
Fungsi aktivasi pada <i>output layer</i>	Linear	Linear
Tipe jaringan	<i>Multi-layer feedforward</i>	<i>Multi-layer feedforward</i>

parameter-parameter yang digunakan dalam ANN. (Zhang & Hu, 1998) mengkaji signifikansi pengaruh jumlah *input* dan arsitektur jaringan dalam memprediksi kurs tukar GBP/USD. Dari hasil penelitiannya, ditemukan bahwa jumlah *input node* memberikan pengaruh lebih besar dibanding jumlah *hidden node*. (Erdogan & Goksu, 2014) mengkaji pengaruh perubahan fungsi transfer dan *learning algorithm* dalam memprediksi kurs tukar LYR/EUR. (Lavanya & Parveentaj, 2013) menggunakan beberapa algoritma *backpropagation* dan menemukan bahwa algoritma LM memberikan prediksi kurs tukar AUD/YEN yang lebih akurat dibanding algoritma lainnya. Hasil yang sama ditemukan oleh (Kumar Chandar et al., 2015) melalui penelitiannya dengan mengaplikasikan lima *learning algorithm* yang berbeda-beda untuk memprediksi kurs tukar INR/PS, INR/USD, INR/EURO/ dan INR/JPY.

Berdasarkan beberapa penelitian terdahulu tersebut, dapat dilihat bahwa penetapan parameter-parameter yang tepat akan meningkatkan performansi ANN baik dari sisi akurasi yang diberikan maupun waktu komputasi yang diperlukan. Secara praktikal, pemilihan parameter-parameter ini menjadi sulit karena adanya perbedaan karakteristik antar mata uang, sehingga belum tentu parameter-parameter yang memberikan hasil optimal untuk suatu mata uang dapat berlaku juga bagi mata uang lainnya. Diperlukan suatu metode untuk menentukan parameter-parameter ANN yang memberikan performansi optimal. Penelitian ini menjawab *gap* penelitian tersebut, khususnya untuk parameter arsitektur jaringan.

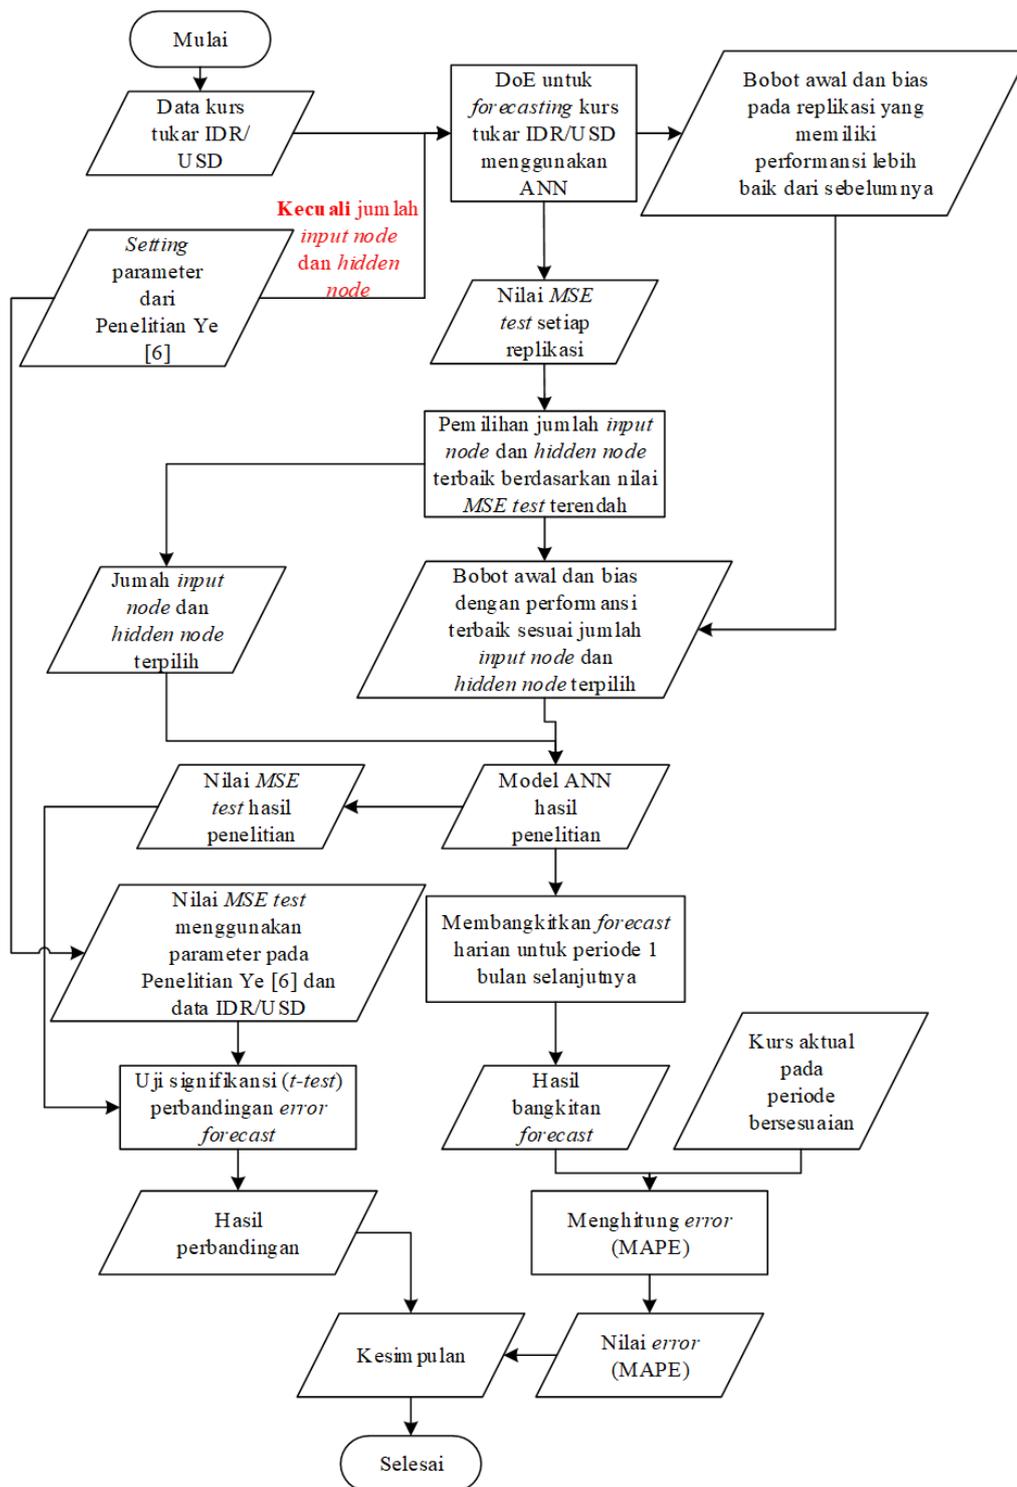
Tujuan dari penelitian ini adalah menentukan arsitektur jaringan yang memberikan hasil prediksi kurs tukar mata uang IDR/USD dengan akurasi yang baik, khususnya dalam hal jumlah *input node* dan jumlah *hidden node* yang digunakan dengan menggunakan *design of experiment* (DoE). Secara teoritis, penelitian ini memperkaya literatur terkait aplikasi ANN untuk memprediksi kurs tukar mata uang IDR/USD khususnya terkait jumlah optimal *input node* dan *hidden node* yang sesuai dengan karakteristik kurs tukar mata uang IDR/USD. Selain itu, penelitian ini juga memberikan *framework* penentuan jumlah *input node* dan *hidden node* optimal untuk kurs tukar mata uang lain melalui konsep *design of experiment* yang digunakan. Secara praktis, penelitian ini dapat membantu dalam pengambilan keputusan di perusahaan. Dengan dimilikinya prediksi kurs tukar mata uang yang memiliki tingkat akurasi yang tinggi,

akan memudahkan perusahaan mengambil keputusan baik strategis, taktis, maupun operasional seperti dalam hal penentuan waktu dan kuantitas pembelian bahan baku impor yang optimal.

Pada penelitian ini, dipilihnya parameter jumlah *input node* dan jumlah *hidden node* sebagai faktor yang dikaji melalui DoE didasarkan pada fakta bahwa kedua hal tersebut memiliki pengaruh yang cukup besar terhadap model ANN yang dibuat. Menurut (Zhang & Hu, 1998), jumlah *node* pada *input layer* merupakan faktor terpenting karena merepresentasikan nilai *lag* yang optimal untuk memprediksi nilai di masa depan. Jumlah *node* pada *hidden layer* dapat menangkap pola nonlinear dan mendeteksi hubungan kompleksitas pada data. Tanpa adanya *hidden node*, jaringan akan seperti model statistik linear. Jaringan dengan jumlah *node* pada *hidden layer* yang terlalu sedikit akan memiliki *power* yang kurang untuk mempelajari data, sementara jika terlalu banyak akan terjadi *overfitting* dan menghasilkan *error forecasting* yang tidak baik.

Dilakukan replikasi sebanyak sepuluh kali pada setiap arsitektur jaringan yang terbentuk. Bobot awal dan bias dari pada replikasi yang memberikan performansi lebih baik dari replikasi sebelumnya dicatat untuk digunakan kembali saat melakukan *forecasting* untuk periode selanjutnya, sehingga hasil *forecast* tersebut sudah menggunakan arsitektur jaringan, bobot awal, dan bias yang memberikan akurasi terbaik. *Setting* parameter lain (selain jumlah *input node* dan jumlah *hidden node*) yang digunakan mengacu pada penelitian (Ye, 2012) karena telah sesuai dengan hasil penelitian (Zhang et al., 1998) mengenai *setting* parameter-parameter yang umum digunakan dalam prediksi kurs tukar mata uang. **Tabel 1** menunjukkan perbandingan *setting* parameter pada penelitian (Ye, 2012) dan penelitian (Zhang et al., 1998) tersebut.

Untuk memastikan bahwa arsitektur jaringan hasil penelitian adalah yang terbaik, dilakukan perbandingan nilai *MSE test* yang dihasilkan dengan menggunakan arsitektur jaringan hasil penelitian dan dengan menggunakan arsitektur jaringan pada penelitian (Ye, 2012). Uji signifikansi *t-test* digunakan untuk melihat signifikansi perbedaan *error forecast* dari kedua arsitektur jaringan yang diperbandingkan tersebut. Selain itu, dibangkitkan juga *forecast* kurs tukar harian selama satu bulan selanjutnya menggunakan arsitektur jaringan, bobot awal, dan bias



Gambar 1. Diagram Alur Penelitian

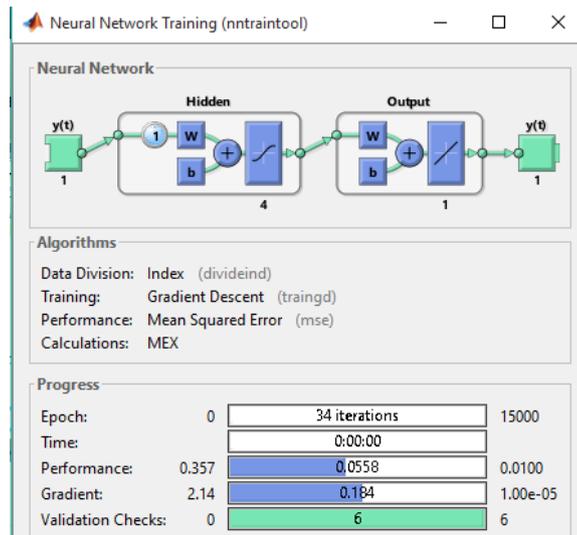
dari hasil penelitian, dan diukur persentase *error*-nya terhadap kurs aktual melalui nilai MAPE.

2. Metode Penelitian

Penelitian ini pada dasarnya bertujuan menentukan arsitektur jaringan terbaik (dalam hal jumlah *input node* dan *hidden node*), bobot awal, dan bias yang memberikan prediksi kurs tukar IDR/USD dengan akurasi terbaik, serta menggunakannya untuk membangkitkan *forecast* selama beberapa periode ke depan. Performansi relatif didasarkan pada perbandingan nilai *MSE test* hasil penelitian dengan

MSE test yang menggunakan data kurs yang sama, namun menggunakan jumlah *input node* dan *hidden node* sesuai pada pada (Ye, 2012). **Gambar 1** menunjukkan bagan alur penelitian.

Penelitian ini menggunakan kurs tukar mata uang Rupiah Indonesia/ US Dollar (IDR/USD) sebagai objek kajian. Digunakan data kurs tukar harian dari 01 Januari 2020 hingga 28 Februari 2022 (total 529 data) yang diambil dari *website* Bank Indonesia (<https://www.bi.go.id/id/statistik/informasi-kurs/jisdor/Default.aspx>). Data tersebut selanjutnya dibagi untuk *training* (70%), validasi (15%), dan tes



Gambar 2. Contoh *Running* Program Model ANN untuk 1 *Input Node* dan 4 *Hidden Nodes*

(15%). Penyelesaian model dilakukan dengan bantuan *software* Matlab R2018.

2.1 Pembagian Set Data

Digunakan data historis kurs jual harian yang diambil dari *website* Bank Indonesia, dari bulan Januari 2020 hingga Februari 2022 (total 529 data):

- Data untuk *training*: kurs tukar dari 2 Januari 2020 hingga 12 Juli 2021 (total 370 data, 70%);
- Data untuk validasi: kurs tukar dari 13 Juli 2021 hingga 05 November 2021 (total 80 data, 15%);
- Data untuk tes: kurs tukar dari 08 November 2021 hingga 25 Februari 2022 (total 79 data, 15%).

2.2 Setting Parameter

a. Arsitektur jaringan

Model ANN yang digunakan terdiri dari satu *input layer*, satu *hidden layer*, dan satu *output layer*. Jumlah *input node* dan *hidden node* ditentukan dengan *design of experiment*. Digunakan sepuluh level untuk faktor *node* pada *input nodes* dan lima level untuk faktor *node* pada *hidden nodes*. Belum terdapat acuan mengenai nilai *autoregressive* yang optimal, sehingga digunakan cukup banyak level (1, 2, ..., 10) untuk mencari jumlah *input node* yang optimal. Terkait jumlah *node* pada *hidden nodes*, berdasarkan literatur dinyatakan bahwa jumlah *hidden nodes* tidak melebihi dua kali jumlah *input nodes*, dan penelitian sebelumnya yang dilakukan oleh (Lachtermacher & Fuller, 1995) menyatakan bahwa performansi *neural network* terhadap *hidden nodes* tidak terlalu sensitif dibandingkan terhadap *input nodes*, sehingga hanya digunakan lima level untuk *hidden nodes* (4,8,12,16, dan 20).

Kombinasi dari sepuluh *input nodes* dan lima *hidden nodes* menghasilkan 50 arsitektur jaringan untuk diuji. Dilakukan *full factorial design of experiment*, dan dilakukan replikasi *training* sebanyak 10 kali untuk masing-masing arsitektur jaringan yang terbentuk. Performansi setiap jaringan diukur berdasarkan kriteria *Mean Squared Error (MSE)*. Nilai

bobot awal dan bias pada replikasi yang memberikan performansi lebih baik dari replikasi sebelumnya dicatat dan nantinya digunakan sebagai bobot awal dan bias untuk model terbaik sehingga setiap program dijalankan akan menghasilkan *error* yang tetap dan yang terbaik karena program tidak lagi membangkitkan bobot awal dan bias secara *random*.

b. Normalisasi data

Dilakukan normalisasi data sehingga data historis ekuivalen dengan nilai yang terletak antara [-1,1].

c. Algoritma dan parameter untuk *training*:

- Algoritma: *backpropagation method*
- *Learning rate*: 0,01
- *Epoch*: 15.000
- *Error goal*: 0,01

d. Fungsi Aktivasi:

- Fungsi aktivasi *hidden layer*: *tanh sigmoidal*
- Fungsi aktivasi *output layer*: linear
- Fungsi *training*: *gradient descent*

e. Ukuran performansi: *Mean Squared Error (MSE)*

3. Hasil dan Pembahasan

Penentuan arsitektur jaringan terbaik dalam hal jumlah *input node* dan jumlah *hidden node* dilakukan melalui *design of experiment*. Dipilih sepuluh *input node* (1,2,3..10) dan lima *hidden nodes* (4,8,12,16,20) sebagai levelnya. Dari kombinasi ini terbentuk 50 arsitektur jaringan. Setiap arsitektur jaringan dijalankan dan direplikasi sebanyak sepuluh kali. Nilai *MSE test* dari kesepuluh replikasi tersebut selanjutnya dirata-rata untuk mewakili nilai *MSE test* atas arsitektur jaringan terkait. Arsitektur jaringan yang memiliki nilai *MSE test* terendah selanjutnya dipilih sebagai arsitektur jaringan terbaik dan dapat digunakan untuk memprediksi kurs tukar IDR/USD sesuai kebutuhan.

Penyelesaian model ANN dilakukan menggunakan *software* Matlab 2018. **Gambar 2** menunjukkan contoh *running* program untuk arsitektur

Tabel 2. Nilai *MSE test* pada Sepuluh Replikasi untuk 1 *Input Node* dan 4 *Hidden Nodes*

Replikasi ke-	MSE Test	Bobot Awal dan Bias							
		IW{1,1}		LW{2,1}			b{1}	b{2}	
1	0.0014	-5.6021	0.3487	-0.1777	0.9894	-0.5463	5.5974	-0.421	
		-5.5996					1.8682		
		5.6461					1.7199		
		-5.6087					-5.589		
2	0.0024								
3	0.0010	-5.682	-0.8756	0.2055	-0.2873	-0.2703	5.5016	0.0711	
		-5.5769					1.9372		
		-5.5894					-1.859		
		-5.6117					-5.587		
4	0.0126								
5	0.0056								
6	0.00094	-5.6019	0.7464	0.8559	0.1811	0.3457	5.5976	0.0408	
		5.5984					-1.871		
		5.6012					1.8641		
		-5.5881					-5.613		
7	0.0025								
8	0.002								
9	0.0018								
10	0.0027								

jaringan 1 *input node* dan 4 *hidden nodes*. Saat berada pada proses *training*, ANN memiliki suatu set bobot awal dan bias. Bobot awal dan bias ini selanjutnya diperbaharui terus-menerus selama fase *training* untuk meningkatkan akurasi *output* hingga pada akhirnya diperoleh bobot dan bias yang optimal. **Tabel 2** menunjukkan hasil pencatatan sepuluh replikasi untuk arsitektur jaringan 1 *input node*, dan 4 *hidden nodes*. Pada **Tabel 2** terdapat nilai *MSE test* yang dihasilkan, bobot awal, dan bias yang ditetapkan oleh masing-masing replikasi. *MSE test* menunjukkan *error* yang dihasilkan. Bobot berperan sebagai koefisien yang menunjukkan kekuatan hubungan antara dua *neuron*, dan bias berperan sebagai konstanta yang ditambahkan pada jumlah hasil kali bobot dan *input* untuk membantu model memberikan hasil yang *fit* dengan data yang ada. Kalkulasi selanjutnya dilakukan sesuai dengan fungsi aktivasi yang digunakan.

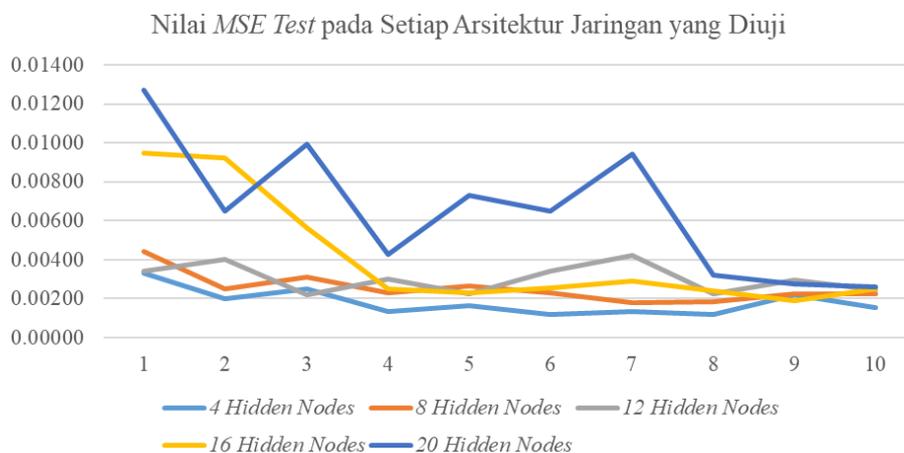
Penentuan bobot awal dan bias yang tepat akan memudahkan *error goal* tercapai sehingga dapat mempersingkat waktu komputasi. Bobot awal “IW{1,1}” menyatakan bobot awal yang digunakan dari *input node* ke *hidden nodes*. Sesuai dengan arsitektur jaringan yang digunakan pada **Tabel 2** (1 *input node* dan 4 *hidden nodes*), ukuran “IW{1,1}” yang dihasilkan adalah 1 x 4. Bobot awal “LW{2,1}” menyatakan bobot awal yang digunakan dari *hidden nodes* ke *output node*. Karena *output* hanya ada satu *node*, maka ukuran dari “LW{2,1}” adalah 4 x 1. Bias “b{1}” merupakan bias yang terkandung pada fungsi aktivasi *hidden layer*. Ukuran dari bias ini adalah 1 x 4 karena *hidden layer* terdiri dari empat *nodes*. Bias “b{2}” merupakan bias yang terkandung pada fungsi aktivasi *output layer*. Karena *output* hanya terdiri dari satu *node*, maka ukuran dari bias ini adalah 1 x 1.

Pada **Tabel 2**, dapat dilihat bahwa replikasi ke-6 memiliki nilai *MSE test* terendah dibandingkan replikasi lainnya. Dapat dinyatakan bahwa replikasi ke-6 memberikan performansi terbaik untuk arsitektur jaringan dengan kombinasi 1 *input node* dan 4 *hidden nodes*. Oleh karena itu bobot awal yang dimiliki replikasi ke-6 akan disimpan sebagai bobot awal dan bias untuk arsitektur jaringan tersebut.

Pada replikasi ke-6 bobot awal dari *input node* ke *hidden nodes* yang digunakan memiliki nilai yang relatif serupa yang berarti kekuatan hubungan yang diberikan dari *input node* kepada keempat *hidden nodes* tidak signifikan berbeda. Adanya perbedaan tanda (positif dan negatif) menunjukkan adanya perbedaan sifat pengaruh yang diberikan. Bobot awal bertanda positif seperti yang dimiliki pada hubungan *input node* dengan *hidden node* ke-2 dan ke-3 menambah nilai *output*, dan sebaliknya, bobot awal bertanda negatif seperti pada hubungan *input node* dengan *hidden node* ke-1 dan ke-4 mengurangi nilai *output*. Bobot awal pada hubungan antara *hidden nodes* dengan *output node* LW{2,1} menunjukkan nilai yang relatif berbeda satu sama lain yang menunjukkan adanya perbedaan kekuatan hubungan antara *hidden nodes* yang satu dan yang lain dengan *output node*. Keempat bobot awal ini bertanda positif yang berarti semua bobot awal yang digunakan menambah nilai *output*. Bias pada fungsi aktivasi di *hidden layer* b{1} menunjukkan nilai bertanda positif pada node ke-1 dan ke-4 yang berarti menambah nilai *output* pada proses kalkulasi, dan bertanda negatif pada node ke-2 dan ke-3 yang berarti mengurangi nilai *output*. Bias pada fungsi aktivasi di *output layer* b{2} memiliki nilai bertanda positif yang berarti menambah nilai *output*.

Tabel 3. Nilai *MSE Test* untuk Setiap Arsitektur Jaringan yang Diuji

Hidden Nodes	Input Nodes									
	1	2	3	4	5	6	7	8	9	10
4	0.00329	0.00200	0.00250	0.00133	0.00166	0.00118	0.00135	0.00117	0.00218	0.00153
8	0.00441	0.00252	0.00312	0.00230	0.00266	0.00231	0.00179	0.00185	0.00226	0.00226
12	0.00342	0.00402	0.00219	0.00301	0.00227	0.00339	0.00423	0.00226	0.00296	0.00245
16	0.00948	0.00920	0.00563	0.00251	0.00228	0.00253	0.00289	0.00242	0.00191	0.00251
20	0.01273	0.00649	0.00991	0.00430	0.00728	0.00651	0.00944	0.00324	0.00278	0.00261



Gambar 3. Perilaku Nilai *MSE Test* pada Setiap Arsitektur Jaringan yang Diuji

Program Matlab dijalankan untuk 49 kombinasi arsitektur jaringan lainnya. **Tabel 3** menunjukkan rangkuman nilai rata-rata performansi tes yang dinyatakan dalam *MSE test* untuk 50 arsitektur jaringan yang terbentuk. Nilai *MSE test* yang ditampilkan merupakan nilai rata-rata dari sepuluh replikasi yang dilakukan. **Gambar 3** menunjukkan perilaku nilai *MSE test* untuk setiap arsitektur jaringan yang diuji. Dari gambar tersebut dapat dilihat bahwa untuk hampir semua level *input nodes* yang diuji, semakin besar *hidden nodes* maka akan semakin besar nilai *MSE test* yang dihasilkan. Dapat dilihat bahwa 20 *hidden nodes* memberikan *MSE test* terbesar dibanding keempat *hidden nodes* lain yang diuji, kecuali pada 2 *input nodes*. Dapat dilihat juga bahwa 4 *hidden nodes* memberikan *MSE test* terkecil dibanding keempat *hidden nodes* lain yang diuji, kecuali pada 3 *input nodes*. Hal ini menandakan bahwa jumlah *hidden nodes* lebih sensitif dibanding jumlah *input nodes*. Hal tersebut bertentangan dengan hasil penelitian (Lachtermacher & Fuller, 1995) yang menyatakan sebaliknya. Dapat disimpulkan bahwa jumlah *input nodes* dan jumlah *hidden nodes* yang digunakan bersifat sensitif tergantung pada pola mata uang yang dikaji. Oleh karena itu, jumlah *input nodes* dan *hidden nodes* yang digunakan bersifat unik dan harus ditetapkan dengan tepat agar memberikan hasil prediksi yang akurat.

Dari **Tabel 3** dapat dilihat bahwa performansi terbaik secara keseluruhan terdapat pada arsitektur jaringan dengan delapan *input nodes* dan empat *hidden nodes* dengan nilai rata-rata *MSE test* terendah, yaitu sebesar 0,00117. Nilai performansi ini dimiliki oleh replikasi ke-3. Berdasarkan pencatatan, bobot awal dan bias pada replikasi tersebut adalah:

IW{1,1}: bobot awal dari *input nodes* ke *hidden nodes*:
 -0.1795 0.0588 -0.8582 0.1495 -0.8055 0.4114
 -0.8568 0.3882;
 0.1318 -0.0329 0.2526 0.9134 0.0146 -1.1141
 0.7209 -0.2824;
 0.5270 0.8189 -0.8395 0.2538 0.7692 -0.3868
 0.1170 0.1267;
 -0.8774 0.2392 -0.2075 0.6033 -0.8075 0.4493
 0.8361 -0.0148

LW{2,1}: bobot awal dari *hidden nodes* ke *output node*:
 -0.6693 0.2175 0.6948 -0.1330

b{1}: bias pada *hidden nodes*:
 1.7578;
 -0.5533;
 0.6312;
 -1.6503

b{2}: bias pada *output node*: 0.2303.

(Ye, 2012) menyatakan bahwa arsitektur jaringan yang terbaik untuk memprediksi kurs tukar mata uang yang dikajinya adalah 10 *input nodes* dan 7 *hidden nodes*. Jika arsitektur jaringan tersebut diaplikasikan menggunakan data kurs tukar IDR/USD pada penelitian ini, nilai rata-rata *MSE test* yang dihasilkan adalah 0.0020 (lebih besar dari nilai *MSE test* hasil arsitektur jaringan terpilih). Hal ini membuktikan bahwa arsitektur jaringan hasil penelitian (delapan *input nodes* dan empat *hidden nodes*) memberikan hasil prediksi yang lebih akurat, dan menandakan bahwa jumlah *input nodes* dan *hidden nodes* bersifat sensitif terhadap jenis kurs yang dikaji.

Tabel 4. Rangkuman Uji *T-Test* untuk Nilai *MSE Test*

<i>MSE Test</i> dengan Arsitektur Jaringan Berdasarkan:		
Replikasi	Hasil penelitian	Penelitian Ye (Ye, 2012)
1	0.00094	0.00190
2	0.00180	0.00130
3	0.00058	0.00110
4	0.00260	0.00083
5	0.00091	0.00320
6	0.00071	0.00068
7	0.00091	0.00120
8	0.00120	0.00220
9	0.00130	0.00350
10	0.00073	0.00410
Rata-Rata	0.00117	0.00200
Variansi	0.00000	0.00000
n	10	10
Sp		0.00091
<i>t test</i>		-2.0475

Tabel 5. Perbandingan Hasil *Forecast* dengan Kurs Aktual Bulan Maret 2022

<i>Forecast</i>	Aktual	<i>Error</i>
14349	14350	0.000070
14359	14373	0.000974
14340	14383	0.002990
14365	14411	0.003192
14346	14394	0.003335
14357	14371	0.000974
14347	14298	0.003427
14348	14306	0.002936
14354	14328	0.001815
14343	14321	0.001536
14355	14311	0.003075
14338	14290	0.003359
14352	14340	0.000837
14340	14341	0.000070
14346	14358	0.000836
14343	14351	0.000557
14339	14361	0.001532
14345	14341	0.000279
14335	14360	0.001741
14344	14364	0.001392
MAPE		0.001746

Hasil uji komparasi nilai *MSE test* yang diperoleh dari model penelitian (0.00117) dan penelitian (Ye, 2012) (0.0020) dilakukan menggunakan *t-test* yang dirangkum pada **Tabel 4**.

$$H_0 = \bar{x}_1 \geq \bar{x}_2$$

$$H_1 = \bar{x}_1 < \bar{x}_2$$

\bar{x}_1 = rerata *MSE test* pada arsitektur jaringan hasil penelitian (delapan *input nodes*, empat *hidden nodes*) = 0,00117

\bar{x}_2 = rerata *MSE test* pada arsitektur jaringan mengikuti penelitian (Ye, 2012) dengan data kurs IDR/USD (sepuluh *input nodes*, tujuh *hidden nodes*) = 0,0020.

Dengan tingkat pengujian pada $\alpha = 0,05$, maka nilai kritis terletak di $t_{0,05;18} = -1,73$. Nilai *t-test* hasil perhitungan adalah -2.0475, karena $t < -1,73$ maka hipotesis nol ditolak yang berarti bahwa “secara signifikan, rerata *MSE test* pada arsitektur jaringan

hasil penelitian (delapan *input nodes*, empat *hidden nodes*) kurang dari rerata *MSE test* pada arsitektur jaringan dari penelitian (Ye, 2012) (sepuluh *input nodes*, tujuh *hidden nodes*)”. Oleh karena itu, arsitektur jaringan delapan *input nodes*, empat *hidden nodes* tepat digunakan untuk memprediksi kurs tukar IDR/USD.

Untuk lebih meyakinkan ketepatan hasil penelitian, selanjutnya dibangkitkan *forecast* kurs tukar IDR/USD periode Maret 2022 menggunakan arsitektur jaringan terpilih, dan bobot awal serta nilai bias yang tersimpan. **Tabel 5** menunjukkan hasil *forecast* tersebut. Jika dibandingkan dengan data kurs Maret 2022 yang diambil dari *website* Bank Indonesia, nilai *error* MAPE yang dihasilkan cukup kecil, yaitu sebesar 0.175%. Hal ini membuktikan bahwa hasil penelitian dapat memberikan hasil *forecast* dengan akurasi cukup baik.

Berdasarkan akurasi *forecast* yang diperoleh, tujuan penelitian ini telah terpenuhi dengan baik, yaitu

memperoleh parameter yang memberikan hasil prediksi kurs tukar mata uang IDR/USD dengan akurasi yang baik, khususnya dalam hal jumlah *input node* dan jumlah *hidden node* yang digunakan serta penetapan bobot awal dan bias. *Framework design of experiment* yang digunakan pada penelitian ini juga dapat diaplikasikan untuk penentuan parameter lain baik pada kurs tukar mata uang IDR/USD maupun kurs tukar mata uang lainnya. Penelitian ini masih memiliki banyak ruang untuk perbaikan, diantaranya adalah pengujian parameter-parameter lain selain jumlah *input nodes* dan *hidden nodes* yang digunakan, seperti fungsi aktivasi, fungsi *training*, dan jumlah *hidden layer* yang sesuai dengan pola kurs tukar mata uang IDR/USD. Kelemahan lain dari penelitian ini adalah masih digunakannya replikasi pada setiap arsitektur jaringan yang diuji untuk menentukan bobot awal dan bias yang baik. Perbaikan dapat dilakukan dengan menentukan bobot awal dan bias menggunakan suatu metode sistematis seperti algoritma pencarian *Harmony* seperti yang dilakukan (Lee et al., 2016), atau algoritma pencarian *Cuckoo* seperti yang dilakukan (Kumar & Tripathi, 2019).

4. Kesimpulan

Penelitian ini bertujuan untuk menentukan arsitektur jaringan terbaik dalam memprediksi kurs tukar mata uang IDR/USD dengan menggunakan *design of experiment*. Terdapat dua faktor yang dikaji, yaitu jumlah *input nodes* dengan nilai level satu hingga sepuluh, dan jumlah *hidden nodes* dengan lima level (4,8,12,16, dan 20). Setiap arsitektur jaringan yang terbentuk, dijalankan sepuluh kali, dan dihitung rata-rata nilai *MSE test* yang dihasilkan. Bobot awal dan bias pada replikasi dengan performansi (nilai *MSE test*) yang lebih baik dari performansi sebelumnya juga dicatat. Hasilnya, jumlah *input nodes* yang terbaik adalah delapan, dan jumlah *hidden nodes* terbaik adalah empat, dengan nilai *MSE test* yang diberikan sebesar 0.00117. Nilai *MSE test* ini lebih kecil dibandingkan dengan *MSE test* yang diberikan oleh arsitektur jaringan hasil penelitian (Ye, 2012) (0.0020). Hasil prediksi kurs tukar Maret 2022 memberikan nilai *error MAPE* yang cukup kecil (0.175%) dibandingkan kurs aktual. Sehingga dapat disimpulkan bahwa hasil penelitian cukup baik dalam memprediksi kurs tukar mata uang IDR/USD. Selain itu, grafik perilaku nilai *MSE test* pada berbagai arsitektur jaringan menunjukkan bahwa jumlah *input nodes* kurang sensitif dibandingkan jumlah *hidden nodes* dalam prediksi kurs tukar mata uang IDR/USD.

5. Daftar Pustaka

Chen, J. C., & Narala, N. H. R. (2017). Forecasting currency exchange rates via Feedforward Backpropagation Neural Network. *Universal Journal of Mechanical Engineering*, 5(3), 77–86. <https://doi.org/10.13189/ujme.2017.050302>

Dunis, C. L., Laws, J., & Schilling, U. (2012). Currency trading in volatile markets: Did neural networks outperform for the EUR/USD during the financial crisis 2007-2009. *Journal of Derivatives and Hedge Funds*, 18(1), 2–41.

<https://doi.org/10.1057/jdhf.2011.31>

Erdogan, O., & Goksu, A. (2014). Forecasting Euro and Turkish Lira Exchange Rates with Artificial Neural Networks (ANN). *International Journal of Academic Research in Accounting, Finance and Management Sciences*, 4(4), 307–316. <https://doi.org/10.6007/ijarafms/v4-i4/1361>

Galeshchuk, S. (2016). Neural networks performance in exchange rate prediction. *Neurocomputing*, 172, 446–452. <https://doi.org/10.1016/j.neucom.2015.03.100>

Jena, P. R., Majhi, R., & Majhi, B. (2015). Development and performance evaluation of a novel knowledge guided artificial neural network (KGANN) model for exchange rate prediction. *Journal of King Saud University - Computer and Information Sciences*, 27(4), 450–457. <https://doi.org/10.1016/j.jksuci.2015.01.002>

Kumar Chandar, S., Sumathi, M., & Sivanandam, S. N. (2015). Forecasting of foreign currency exchange rate using neural network. *International Journal of Engineering and Technology*, 7(1), 99–108. <https://doi.org/10.1109/ICGHIT.2019.00021>

Kumar, V., & Tripathi, M. M. (2019). Weight and bias initialization of ANN for load forecasting using cuckoo search algorithm. *Proceedings - 2019 7th International Conference on Green and Human Information Technology, ICGHIT 2019, January*, 60–65. <https://doi.org/10.1109/ICGHIT.2019.00021>

Lachtermacher, G., & Fuller, J. D. (1995). *Backpropagation in Time-series Forecasting*. 14, 381–393.

Lavanya, V., & Parveentaj, M. (2013). Foreign Currency Exchange Rate (FOREX) using Neural Network. *International Journal of Science and Research*, 2(10), 174–177. https://www.academia.edu/5320333/Foreign_Currency_Exchange_Rate_FOREX_using_Neural_Network

Lee, A., Geem, Z. W., & Suh, K. D. (2016). Determination of optimal initial weights of an artificial neural network by Using the harmony search algorithm: Application to breakwater armor stones. *Applied Sciences (Switzerland)*, 6(6). <https://doi.org/10.3390/app6060164>

Meng, L., & Sun, Y. (2013). Research on automated forex trading system based on BP neural network. *Advanced Materials Research*, 753–755, 3080–3083. <https://doi.org/10.4028/www.scientific.net/AMR.753-755.3080>

Nag, A. K., & Mitra, A. (2002). Forecasting daily foreign exchange rates using genetically optimized neural networks. *Journal of Forecasting*, 21(7), 501–511. <https://doi.org/10.1002/for.838>

Nizar, M. A. (2012). Pengaruh Jumlah Turis Dan Devisa Pariwisata Terhadap Nilai Tukar Rupiah. *Jurnal Kepariwisata Indonesia*, 7(2). <https://ideas.repec.org/p/pramprapa/65629.htm>

- Panda, C., & Narasimhan, V. (2007). Forecasting exchange rate better with artificial neural network. *Journal of Policy Modeling*, 29(2), 227–236.
<https://doi.org/10.1016/j.jpolmod.2006.01.005>
- Rout, A. (2013). Efficient Forecasting of Exchange rates with Recurrent FLANN. *IOSR Journal of Computer Engineering*, 13(6), 21–28.
<https://doi.org/10.9790/0661-1362128>
- Thakur, G. S. M., Bhattacharyya, R., & Mondal, S. S. (2016). Artificial Neural Network Based Model for Forecasting of Inflation in India. *Fuzzy Information and Engineering*, 8(1), 87–100.
<https://doi.org/10.1016/j.fiae.2016.03.005>
- Thorbecke, W., & Kato, A. (2012). The effect of exchange rate changes on Japanese consumption exports. *Japan and the World Economy*, 24(1), 64–71.
<https://doi.org/10.1016/j.japwor.2011.12.004>
- Tung, L. T. (2019). Does exchange rate affect the foreign tourist arrivals? Evidence in an emerging tourist market. *Management Science Letters*, 9(8), 1141–1152.
<https://doi.org/10.5267/j.msl.2019.5.001>
- Ye, S. (2012). RMB Exchange Rate Forecast Approach Based on BP Neural Network. *Physics Procedia*, 33.
<https://doi.org/10.1016/j.phpro.2012.05.064>
- Zhang, G., Eddy Patuwo, B., & Y. Hu, M. (1998). Forecasting with artificial neural networks: The state of the art. In *International Journal of Forecasting* (Vol. 14, Issue 1).
[https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7)
- Zhang, G., & Hu, M. Y. (1998). Neural network forecasting of the British pound/US dollar exchange rate. *Omega*, 26(4), 495–506.
[https://doi.org/10.1016/S0305-0483\(98\)00003-6](https://doi.org/10.1016/S0305-0483(98)00003-6)
- Zhao, Y. (2020). The influence and impact of the exchange rate on the economy. *E3S Web of Conferences*, 214.
<https://doi.org/10.1051/e3sconf/202021403007>
- Peraturan BI mengenai Sistem Pembayaran, diperoleh melalui situs internet:
http://www.bi.go.id/id/peraturan/sistem-pembayaran/Pages/pbi_170315.aspx.
 Diunduh pada 27 Mei 2017.