

Comparison of Feedforward Neural Network and Classical Statistics Methods: Application in Finance

Perbandingan Metode *Feedforward Neural Network* dan Metode Statistika Klasik: Aplikasi di Bidang Finansial

Prilyandari Dina Saputri^{1*}, Pratnya Paramitha Oktaviana^{2*}

*Departemen Aktuaria, Institut Teknologi Sepuluh Nopember, Surabaya

Email address: prilyandaridina@its.ac.id¹, paramita@statistika.its.ac.id²

Received: 9 February 2023; Accepted: 3 April 2023; Published: 5 May 2023

Abstract

The flexibility and elevated accurateness of the statistical machine learning method makes this method widely applied in various fields. One of the statistical machine learning methods is the neural network, which can be used for data analysis. The great performance of the neural network method can be used in the field of finance. In this study, the neural network method was used to predict Non-Performing Loans (NPL) data and forecast credit receivables. In the NPL prediction, the banks used are State-Owned Banks, Regional Government Banks, and National Private Banks with a main capital of more than 6 trillion rupiahs in March 2021, i.e. 26 banks with the period of March 2018 until March 2021. In predicting NPL, a moving window scheme involves several different periods. In the forecast of the number of credit receivables, the data used is the number of financing receivables. The period from November 2012 to December 2020 is used as training data, while data for the period from January to June 2021 is used as testing data. The results of the analysis show that the neural network for NPL prediction and credit receivables forecasting shows better performance compared to classical methods such as multiple linear regression and ARIMA. A comparison of methods for banking NPLs prediction is based on the RMSE data testing values, while forecasting credit receivable is based on RMSE, MAE, and MAPE data testing values.

Keywords: Finance, Neural Network, Statistics

Abstrak

Fleksibilitas dan akurasi yang tinggi dari metode *statistical machine learning* membuat metode ini banyak diaplikasikan pada berbagai bidang. Salah satu metode dalam *machine learning* adalah *neural network*, yang dapat digunakan untuk analisis data. Akurasi yang tinggi dari



JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

Prilyandari Dina Saputri, Pratnya Paramitha Oktaviana

metode *neural network* juga dapat dimanfaatkan dalam bidang pengawasan lembaga keuangan. Pada penelitian ini, metode *neural network* akan digunakan untuk prediksi data *Non-Performing Loans* (NPL) dan peramalan piutang kredit. Pada prediksi NPL, perbankan yang digunakan adalah Bank Persero, Bank Pemerintah Daerah, dan Bank Swasta Nasional dengan modal inti lebih dari 6 triliun rupiah pada Maret 2021, yakni sebanyak 26 perbankan. Periode data yang digunakan adalah Maret 2018 hingga Maret 2021. Dalam memprediksi NPL, juga akan digunakan skema *moving window*, yakni memprediksi NPL pada periode yang berbeda. Pada analisis peramalan besarnya piutang kredit, data yang digunakan adalah jumlah piutang pembiayaan dengan periode November 2012 hingga Desember 2020 digunakan sebagai data *training*, sedangkan data periode Januari hingga Juni 2021 digunakan sebagai data *testing*. Hasil analisis menunjukkan bahwa metode *neural network* yang digunakan untuk prediksi NPL perbankan dan juga peramalan piutang kredit lembaga pembiayaan menunjukkan performa yang lebih baik dibandingkan dengan metode klasik seperti regresi linier berganda dan juga ARIMA. Perbandingan metode untuk prediksi NPL perbankan dilakukan berdasarkan nilai RMSE data *testing*, sedangkan pada peramalan piutang dilakukan berdasarkan nilai RMSE, MAE, dan MAPE data *testing*.

Kata kunci: Finansial, Neural Network, Statistika.

1. PENDAHULUAN

1.1 Latar Belakang

Artificial Intelligence (AI) atau kecerdasan buatan merupakan suatu sistem yang memiliki kemampuan untuk mempelajari suatu karakteristik dan kemudian dapat menghasilkan suatu kesimpulan. Sistem ini didesain untuk dapat berpikir seperti manusia, sehingga seringkali disebut sebagai kecerdasan buatan [1]. Pengembangan algoritma pada *artificial intelligence* juga dapat disebut sebagai *machine learning*. Terdapat beberapa metode *machine learning* yang telah dikembangkan, diantaranya adalah *neural network*, *support vector machine*, *random forest*, dan lain sebagainya. Metode-metode tersebut tentunya memiliki algoritma yang berbeda, namun juga dapat diaplikasikan pada berbagai bidang. Pada penelitian ini, metode *machine learning* yang digunakan adalah *artificial neural network*.

Metode *neural network* dapat diaplikasikan untuk sistem syaraf model biologis, prosesor/kontroler sinyal adaptif realtime pada robot, hingga untuk analisis data [2]. Analisis data menggunakan *neural network* pada umumnya akan menghasilkan tingkat akurasi yang tinggi dibandingkan dengan penggunaan metode statistika klasik. Penelitian sebelumnya menunjukkan bahwa metode *neural network* memiliki performa yang lebih baik dibandingkan dengan metode regresi linier berganda, yakni dalam prediksi konsentrasi SO₂ [3], prediksi kadar hidrogen pada proses pertukaran di membran sel [4], peramalan penggunaan listrik [5] dan pada beberapa kasus lainnya. Untuk permasalahan klasifikasi, metode *neural network* juga memiliki performa yang lebih baik apabila dibandingkan dengan metode analisis diskriminan [6], [7] maupun regresi logistik [8]–[10]. Sedangkan pada permasalahan peramalan, metode *neural network* dapat meramalkan secara lebih akurat dibandingkan dengan metode ARIMA [11]–[13].

Pada dasarnya, metode *machine learning* memiliki tujuan utama untuk memperoleh hasil prediksi maupun model yang lebih akurat, dengan menggunakan algoritma yang lebih kompleks dan banyak menggunakan *trial and error*. Sedangkan pembentukan model menggunakan metode statistika seringkali ditujukan untuk menginterpretasikan pola hubungan didalam suatu model. Sehingga dalam membentuk model *machine learning* juga diperlukan prinsip dari metode statistika. Penggunaan prinsip metode statistik dalam analisis data menggunakan *machine learning* tentunya diharapkan dapat meningkatkan performa akurasi pada metode *machine learning* [2].

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

Prilyandari Dina Saputri, Pratnya Paramitha Oktaviana

Akurasi yang tinggi dari metode *neural network* ini membuat metode *neural network* banyak diaplikasikan pada berbagai bidang. Pada bidang finansial, metode *neural network* dapat diaplikasikan untuk prediksi kebangkrutan perbankan [14], *scoring* risiko perbankan [15], *early warning* kondisi finansial [16], prediksi risiko likuiditas [17], dan lain sebagainya. Pemodelan pada bidang finansial juga membutuhkan akurasi yang tinggi, sehingga metode *neural network* tepat digunakan. Penggunaan model *neural network* dengan akurasi yang tinggi ini tentunya juga dapat dimanfaatkan sebagai solusi dalam melakukan pengawasan terhadap lembaga keuangan di Indonesia. Prediksi yang akurat mengenai kondisi suatu lembaga keuangan dapat digunakan sebagai *early warning* dan menentukan kebijakan untuk lembaga keuangan tersebut.

Penelitian ini mengimplementasikan penggunaan metode *neural network* pada permasalahan prediksi dan peramalan. Model *neural network* akan digunakan untuk memprediksi besarnya nilai *Non Performing Loan* (NPL) Bank Umum Konvensional. Prediksi NPL ini dapat digunakan sebagai *early warning* dalam pengawasan kinerja perbankan di Indonesia. Otoritas Jasa Keuangan juga telah menetapkan batas maksimal NPL bagi perbankan, yakni sebesar 5%. Apabila sebuah perbankan memiliki rasio NPL lebih dari 5%, maka perbankan tersebut akan masuk kedalam pengawasan intensif karena dinilai mengalami potensi kesulitan yang dapat membahayakan keberlangsungan usahanya [18]. Di Indonesia, besarnya NPL ini diduga dipengaruhi oleh KPMM, ROA, ROE, NIM, BOPO, LDR dan Aset [19], [20]. Sehingga variabel tersebut akan digunakan sebagai variabel *input* pada pemodelan *neural network*. Variabel suku bunga *BI rate* juga akan ditambahkan sebagai variabel *input*, karena data yang digunakan merupakan data panel, sehingga untuk mengakomodasi adanya dependensi antar pengamatan, digunakan variabel tingkat suku bunga *BI rate* sebagai variabel makroekonomi. Selanjutnya akan dilakukan perbandingan akurasi dari model *neural network* dengan model regresi linier berganda berdasarkan nilai *Root Mean Square Error* (RMSE).

Pada permasalahan peramalan, metode *neural network* akan digunakan untuk meramalkan besarnya kredit yang diberikan oleh Lembaga Pembiayaan beberapa periode kedepan. Pada lembaga pembiayaan, pendapatan utamanya diperoleh dari kegiatan pemberian kredit kepada masyarakat. Sehingga peramalan pemberian kredit menjadi hal yang penting untuk dilakukan. Pemilihan *input* pada analisis menggunakan *neural network* dilakukan menggunakan prinsip metode statistika yakni berdasarkan korelasi antar periode yang berbeda. Peramalan pemberian kredit pernah dilakukan untuk kredit modal kerja di Bank Mandiri [21] dan juga penyaluran kredit oleh BPD [22] yang menggunakan metode ARIMA. Sehingga, untuk mengetahui performa dari *neural network* dalam peramalan, akan dilakukan perbandingan dengan metode ARIMA. Evaluasi performa ini juga dilakukan berdasarkan nilai RMSE.

Pada penelitian ini, dilakukan analisis prediksi NPL berdasarkan rasio keuangan menggunakan metode *neural network* dan dibandingkan dengan metode klasik yakni regresi linier berganda. Penerapan dibidang finansial juga dilakukan pada peramalan pemberian kredit oleh lembaga pembiayaan menggunakan metode *neural network* dan dibandingkan dengan metode ARIMA. Dengan demikian, berdasarkan analisis yang dilakukan dapat diperoleh kesimpulan mengenai implementasi metode *machine learning* dalam berbagai permasalahan untuk pengawasan lembaga keuangan dan bagaimana proses analisis menggunakan *machine learning* untuk memprediksi NPL serta meramalkan pemberian kredit.

1.2 Studi Literatur

Feedforward Neural Network adalah model yang fleksibel untuk mengembangkan model regresi non-linier, model reduksi data, dan model sistem dinamis non-linier. Model *feedforward neural network* memuat banyak *neuron* sebagai penyusunnya. *Neuron* dalam model *feedforward neural network* ini saling berhubungan secara rumit dan tersusun berlapis-lapis. *Feedforward neural network* dapat memproses data dalam jumlah besar dan membuat prediksi yang sangat akurat [2]. Metode FFNN bekerja dengan cara menerima vektor input kemudian menghitung output

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

Prilyandari Dina Saputri, Pratnya Paramitha Oktaviana

dengan memproses input melalui elemen-elemen yang saling berhubungan. Elemen proses disusun dalam beberapa bagian (lapisan) dan input diproses secara berurutan dari satu lapisan ke lapisan selanjutnya [23]. Terdapat beberapa komponen yang dapat menentukan tingkat akurasi metode *feedforward neural network*, yakni arsitektur jaringan, metode pelatihan atau algoritma, dan fungsi aktivasi [24]. Persamaan untuk model FFNN yang memiliki input sebanyak p , satu *hidden layer* dengan *neuron* sebanyak m dapat dituliskan sebagai:

$$f(x_t, \mathbf{v}, \mathbf{w}) = g_2 \left\{ \sum_{j=0}^m v_j g_1 \left[\sum_{i=0}^p w_{ji} x_{it} \right] \right\} \quad (3)$$

dengan \mathbf{w} adalah suatu vektor pembobot yang menghubungkan lapisan *input* dengan lapisan *hidden*, sedangkan \mathbf{v} adalah suatu vektor pembobot yang menghubungkan lapisan *hidden* dengan lapisan *output* (respon), $g_1(\cdot)$ dan $g_2(\cdot)$ adalah fungsi aktivasi yang digunakan untuk mentransformasi pada setiap lapisan, sedangkan w_{ji} dan v_j adalah bobot yang diestimasi dengan proses *backpropagation*. [2].

2. METODOLOGI PENELITIAN

Data yang digunakan untuk prediksi NPL perbankan merupakan data Laporan Publikasi Bank Umum Konvensional Triwulanan yang dapat diakses pada *website* Otoritas Jasa Keuangan (<https://www.ojk.go.id/>). Perbankan yang menjadi pengamatan dalam analisis ini adalah Bank Persero, Bank Pemerintah Daerah, dan Bank Swasta Nasional dengan modal inti lebih dari 6 triliun rupiah pada Maret 2021, yakni sebanyak 26 perbankan. Periode data yang digunakan adalah Maret 2018 hingga Maret 2021. Pada analisis peramalan besarnya pemberian kredit, data yang digunakan juga diperoleh dari *website* Otoritas Jasa Keuangan (<https://www.ojk.go.id/>) yakni jumlah piutang pembiayaan pada data statistik lembaga pembiayaan yang disusun dalam periode bulanan. Data periode November 2012 hingga Desember 2020 digunakan sebagai data *training*, sedangkan data periode Januari hingga Juni 2021 digunakan sebagai data *testing*.

Tabel 2.1. Variabel Penelitian

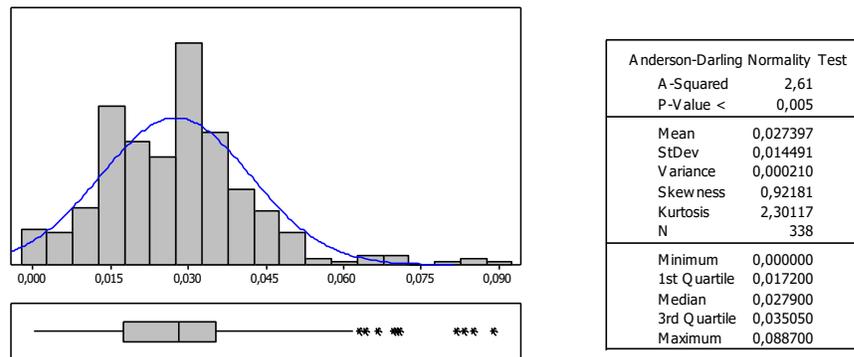
Analisis	Variabel
Prediksi NPL	<i>Output Non Performing Loan (NPL)</i>
	<i>Input</i> Kewajiban Penyediaan Modal Minimum (KPMM) (%)
	<i>Return on Asset (ROA) (%)</i>
	<i>Return on Equity (ROE) (%)</i>
	<i>Net Interest Margin (NIM) (%)</i>
	Beban Operasional terhadap Pendapatan Operasional (BOPO) (%)
	<i>Loan to Deposit Ratio (LDR) (%)</i>
	Aset (Juta rupiah)
	Suku Bunga BI rate (%)
	Peramalan pemberian kredit

3. HASIL DAN PEMBAHASAN

3.1. Prediksi *Non-Performing Loan* pada Perbankan

Dalam melakukan analisis data rasio keuangan, perlu dilakukan identifikasi adanya *missing value*. Apabila terdapat *missing value* pada data rasio keuangan, maka perlu dilakukan penanganan untuk mengatasi *missing value*. Hal ini dikarenakan metode yang digunakan tidak dapat

mengakomodasi adanya *missing value* secara langsung. Pada data rasio keuangan perbankan, terdapat *missing value* pengamatan sebanyak 1,18%. *Missing value* tersebut dikarenakan terdapat yang kosong pada laporan publikasi beberapa perbankan. Untuk mengatasi *missing value*, dilakukan imputasi *K-Nearest Neighbor* untuk setiap perbankan. Setelah dilakukan imputasi, akan diidentifikasi karakteristik NPL melalui sebaran histogram data NPL pada Gambar 3.1.



Gambar 3.1. Karakteristik Data NPL Perbankan

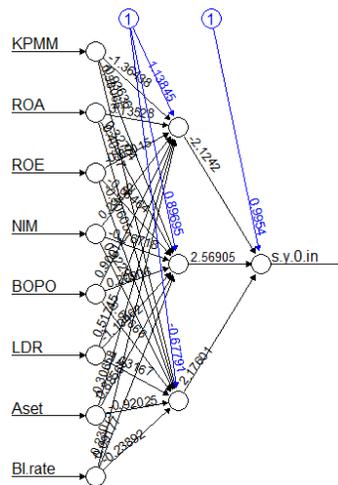
Gambar 3.1 menunjukkan bahwa mayoritas NPL perbankan berada di sekitar 2,75% hingga 3,25% yang ditandai oleh bar tertinggi dari histogram. Nilai rata-rata dari NPL perbankan mendekati nilai median yakni disekitar 2,74%. Hal ini menunjukkan bahwa terdapat pola simetris dari data NPL. Namun demikian, berdasarkan histogram juga terlihat bahwa terdapat pencilan atau nilai NPL yang berada jauh lebih tinggi dibandingkan nilai lainnya, yakni NPL perbankan yang lebih dari 6,5%.

Analisis menggunakan *neural network* dilakukan pada berbagai *time window*. Pada *window size 0*, variabel *input* yang digunakan adalah variabel *input* dengan periode yang sama dengan variabel *output*. Pada *window size 1*, variabel *input* yang digunakan adalah variabel *input* satu periode sebelumnya. Pada *window size 2*, variabel *input* yang digunakan adalah variabel *input* dua periode sebelumnya. Penggunaan *window size* yang berbeda bertujuan untuk mengetahui akurasi dari prediksi untuk periode yang sama maupun periode yang berbeda. *Input* yang digunakan untuk ketiga *time window* adalah sama, yakni KPMM, ROA, ROE, NIM, BOPO, LDR, Aset, serta suku bunga BI rate. Pengujian linieritas antara *input* dan *output* dilakukan dengan hipotesis awal yang digunakan adalah pola hubungan antara *input* dan *output* linier. Pengujian linieritas dilakukan menggunakan uji terasvirta, diperoleh nilai *p-value* <0,001 untuk ketiga *window size*. Sehingga terdapat pola hubungan nonlinier antara *input* dan *output*. Dalam model *neural network*, banyaknya *neuron* yang digunakan adalah 1, 2, 3, 4, 5, 10, dan 15. Tabel 3.1 menunjukkan perbandingan RMSE untuk *neuron* yang digunakan pada ketiga *time window*.

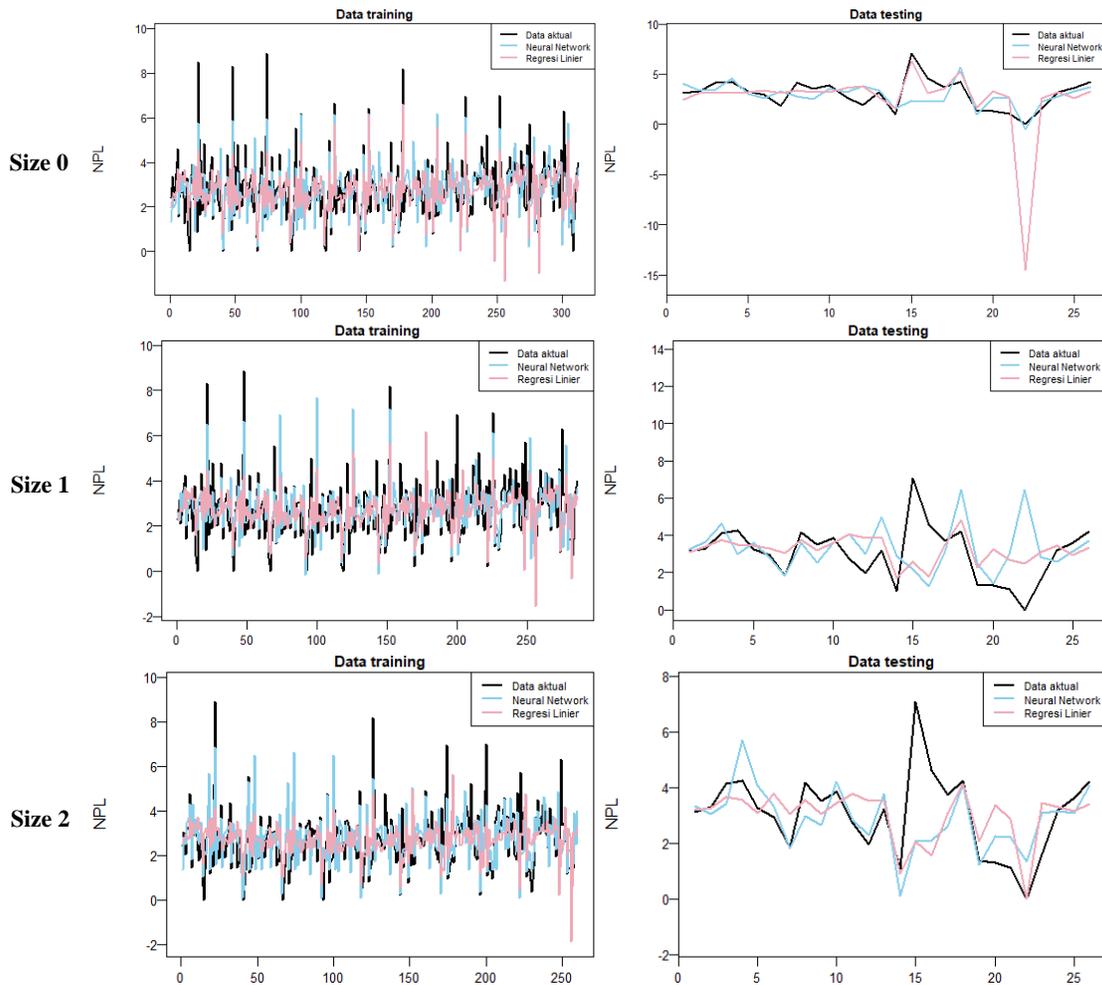
Tabel 3.1. Perbandingan RMSE Neuron Model Prediksi NPL

Neuron	Training			Testing		
	Size 0	Size 1	Size 2	Size 0	Size 1	Size 2
Neuron 1	1,084	1,137	1,156	1,562	1,505	1,537
Neuron 2	0,850	0,956	1,010	1,970	1,298	1,252
Neuron 3	0,874	0,902	0,821	1,356	1,980	1,331
Neuron 4	0,837	0,666	0,929	1,476	2,555	1,432
Neuron 5	0,647	0,697	0,722	1,482	2,270	1,936
Neuron 10	0,649	0,511	0,584	1,636	1,799	1,728
Neuron 15	0,542	0,634	0,541	1,424	1,544	1,453

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI
Prilyandari Dina Saputri, Pratnya Paramitha Oktaviana



Gambar 1.2 Arsitektur Model *Neural Network* Prediksi NPL untuk *Window Size 0*



Gambar 3.3. Perbandingan Data Aktual dan Ramalan Prediksi NPL

Berdasarkan Tabel 3.1, terlihat bahwa arsitektur yang digunakan untuk ketiga *window size* adalah berbeda. Untuk prediksi NPL pada periode yang sama (*window size = 0*), jumlah *neuron*

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

Prilyandari Dina Saputri, Pratnya Paramitha Oktaviana

optimal adalah 3 *neuron*. Sedangkan prediksi NPL berdasarkan satu dan dua periode sebelumnya (*window size* 1 dan 2), jumlah *neuron* optimalnya adalah 2 *neuron*. Dengan demikian, arsitektur model *neural network* untuk *window size* 0 dapat ditunjukkan oleh Gambar 3.2. Setelah diperoleh model *neural network* untuk ketiga *window size*, akan dilakukan perbandingan dengan metode regresi linier berganda. Perbandingan secara grafis dengan sumbu x merupakan perbankan pada berbagai periode dan sumbu y merupakan NPL dapat ditunjukkan pada Gambar 3.3.

Gambar 3.3 menunjukkan bahwa pada data *training*, model *neural network* dapat menangkap pola data aktual yang lebih ekstrim dibandingkan dengan metode regresi linier berganda. Pada data *testing*, model *neural network* juga memiliki selisih NPL yang lebih kecil dibandingkan model regresi linier berganda. Hal ini berlaku untuk seluruh *window size* yang digunakan. Selanjutnya juga akan dilakukan perbandingan berdasarkan nilai RMSE. Berikut adalah RMSE untuk model *neural network* (NN) dan regresi linier berganda (RLB).

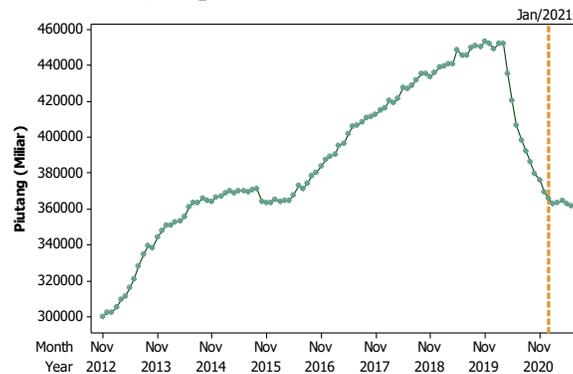
Tabel 2.2. Perbandingan RMSE RLB dan NN

Size	Training		Testing	
	RLB	NN	RLB	NN
0	1,10	0,87	3,00	1,36
1	1,14	0,96	1,43	1,30
2	1,18	1,01	1,44	1,25

Tabel 3.2 menunjukkan bahwa metode *neural network* dapat memprediksi NPL dengan lebih baik dibandingkan metode regresi linier berganda pada *window size* 0, 1, dan 2. Untuk data *testing*, RMSE terkecil justru berasal dari *window size* 2, yang berarti kondisi perbankan 2 periode sebelumnya dapat memprediksi NPL dengan lebih baik. Dengan demikian, prediksi NPL berdasarkan data KPMM, ROA, ROE, NIM, BOPO, LDR, Aset, serta suku bunga BI *rate* menggunakan model *neural network* memiliki akurasi yang lebih baik dibandingkan dengan model regresi linier berganda.

3.2. Peramalan Penyaluran Kredit oleh Lembaga Pembiayaan

Pemberian kredit oleh lembaga pembiayaan dari periode November 2012 hingga Juni 2021 dapat digambarkan oleh *time series plot* pada Gambar 3.4.



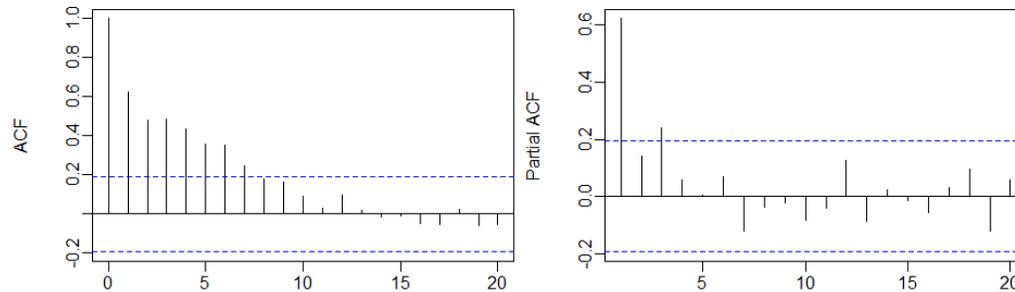
Gambar 3.4. Time Series Plot Piutang Kredit oleh Lembaga Pembiayaan

Berdasarkan *time series plot* pada Gambar 3.4, pemberian kredit oleh lembaga pembiayaan mengalami tren peningkatan hingga awal tahun 2020. Sejak bulan maret 2020 terjadi penurunan yang dapat disebabkan oleh adanya COVID-19 yang berdampak pada perekonomian Indonesia. Metode *neural network* dan ARIMA akan digunakan untuk meramalkan data *testing* piutang kredit. Perbandingan kedua metode tersebut juga dilakukan untuk mengetahui kebaikan model *neural network* dan ARIMA dalam melakukan peramalan apabila terdapat perubahan pola tren pemberian kredit oleh lembaga pembiayaan.

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

Prilyandari Dina Saputri, Pratnya Paramitha Oktaviana

Dalam penentuan *input* model *time series*, akan dilakukan berdasarkan *Partial ACF* (PACF) data piutang yang telah stasioner. Pengujian stasioneritas data telah dilakukan menggunakan uji *dickey fuller* dengan hipotesis awal adalah data tidak stasioner. Hasil yang diperoleh adalah hipotesis awal gagal ditolak dengan *p-value* sebesar 0,837, sehingga data piutang tidak stasioner dalam mean. Selanjutnya, identifikasi *input* akan dilakukan berdasarkan PACF dari data piutang yang telah dilakukan *differencing*. Berikut adalah PACF data piutang yang telah dilakukan *differencing*.



Gambar 3.5. Plot ACF dan PACF Data Piutang Stasioner

Berdasarkan Gambar 3.5, terlihat bahwa *lag* yang signifikan adalah *lag 1* dan *lag 3*, namun pada *lag 3*, nilai PACF nya hanya sedikit melebihi batas signifikansi. Sedangkan pada *lag 2*, juga hampir melebihi batas signifikansi. Untuk menentukan *input* optimal, akan dicobakan 3 jenis *input* yakni *input* berupa *lag 1*, *input* berupa *lag 1* dan 3, serta *input* berupa *lag 1, 2, dan 3*. Selanjutnya akan dilakukan uji linieritas antara *output* dengan ketiga kemungkinan *input*. Hipotesis awal yang digunakan adalah pola hubungan antara *input* dan *output* linier. Hasil pengujian menggunakan uji *terasvirta* dapat ditunjukkan oleh Tabel 3.3.

Tabel 3.3. Uji Linieritas *Input* dan *Output*

Lag	χ^2	p-value	Kesimpulan
Lag 1	5,275	0,072	Linier
Lag 1 dan 3	32,528	<0,001	Non linier
Lag 1, 2, dan 3	43,687	<0,001	Non linier

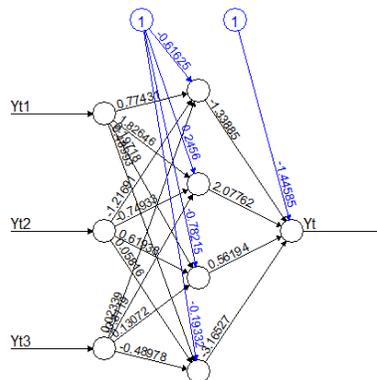
Tabel 3.3 menunjukkan bahwa hubungan linier antara *input* dan *output* hanya terjadi pada *lag 1*. Sedangkan penggunaan lebih dari 1 *input*, yakni *lag 1* dan 3, serta *lag 1, 2, dan 3* menunjukkan hubungan yang nonlinier. Dengan demikian, metode non linier tentunya akan lebih tepat digunakan. Dari ketiga *input* tersebut, akan dilakukan estimasi parameter hingga diperoleh nilai evaluasi data *training* dan data *testing*. Tabel 3.4 menunjukkan perhitungan RMSE untuk seluruh kemungkinan *input* dan *neuron* yang dicobakan.

Tabel 3.4. Perbandingan Kriteria untuk Kombinasi *Input* dan *Neuron*

<i>Input</i>	<i>Neuron</i>	<i>Training</i>			<i>Testing</i>		
		RMSE	MAE	MAPE	RMSE	MAE	MAPE
<i>Lag 1</i>	1	4.015,543	2.727,801	0,695	9.204,410	8.874,434	2,443
	2	3.943,832	2.679,856	0,680	7.938,657	7.714,296	2,124
	3	3.934,395	2.647,355	0,669	7.729,935	7.518,274	2,070
	4	3.942,364	2.650,405	0,671	7.344,947	7.153,376	1,969
	5	3.920,335	2.586,015	0,652	7.719,523	7.500,087	2,065

	10	3.946,464	2.696,916	0,684	8.600,339	8.332,057	2,294
	15	3.972,040	2.744,991	0,699	9.013,042	8.716,109	2,400
Lag 1 dan 3	1	3.202,463	2.199,538	0,558	3.562,767	3.007,595	0,828
	2	3.115,040	2.136,151	0,539	4.360,205	4.085,116	1,125
	3	2.785,382	1.864,727	0,478	20.223,386	16.412,568	4,523
	4	2.918,467	1.972,205	0,503	13.635,154	11.665,062	3,213
	5	3.034,073	2.052,914	0,524	2.710,700	2.356,641	0,649
	10	3.104,946	2.134,340	0,541	2.974,610	2.719,648	0,749
	15	2.671,213	1.756,706	0,450	1.893,785	1.747,723	0,481
Lag 1, 2, dan 3	1	3.134,893	2.160,220	0,549	3.524,863	2.883,147	0,794
	2	2.952,063	1.953,796	0,498	3.365,454	2.983,407	0,822
	3	2.988,773	2.029,562	0,512	2.383,782	2.030,979	0,560
	4	2.621,506	1.752,394	0,451	1.712,122	1.337,104	0,368
	5	2.765,260	1.887,635	0,488	2.086,645	1.518,478	0,417
	10	2.500,047	1.614,470	0,413	4.304,082	3.748,660	1,033
	15	2.666,287	1.799,569	0,459	3.352,106	3.128,310	0,862

Nilai kriteria untuk seluruh kemungkinan *input* dan *neuron* yang dicobakan menunjukkan bahwa *input* dengan lag 1, 2, dan 3 menghasilkan akurasi terbaik pada berdasarkan nilai RMSE, MAE, dan MAPE data *testing*. Dengan demikian, arsitektur model *neural network* yang digunakan adalah *neuron* sebanyak 4, *input lag* 1, 2, dan 3, fungsi aktivasi *tanh*, dan 1 *hidden layer*. Arsitektur ini dapat ditunjukkan oleh Gambar 3.6.



Gambar 3.6. Arsitektur Model *Neural Network* Peramalan Piutang Kredit

Setelah diperoleh model *neural network* optimal, akan dilakukan perbandingan dengan metode ARIMA. Telah dicobakan beberapa model ARIMA yakni ARIMA (1,1,0), ARIMA (2,1,0), ARIMA (3,1,0), serta ARIMA ([1,3],1,0). Model ARIMA yang seluruh komponennya signifikan dan memenuhi asumsi residual *white noise* serta berdistribusi normal adalah model ARIMA ([1,3],1,0). Selanjutnya akan dilakukan perbandingan model *neural network* optimal dengan ARIMA optimal, yang ditunjukkan oleh Tabel 3.5.

Tabel 3.5. Perbandingan Kriteria Metode ARIMA dan *Neural Network*

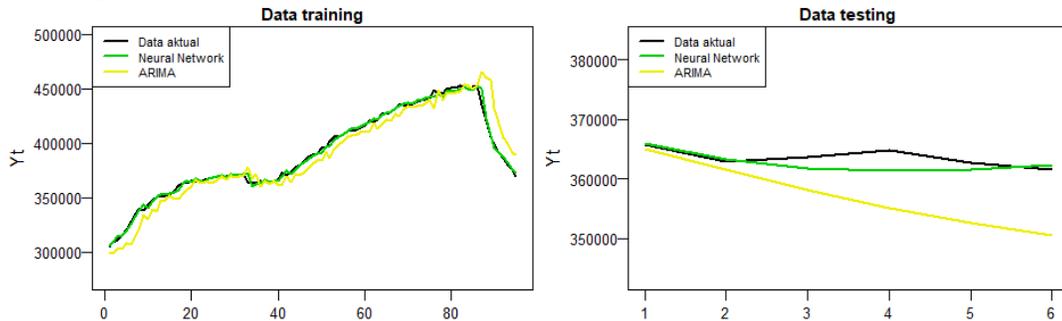
Metode	Training			Testing		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE
NN	2621,506	1752,394	0,451	1712,122	1337,104	0,368
ARIMA	12131,400	8618,372	2,247	7623,378	6399,828	1,763

Tabel 3.5 menunjukkan bahwa, pada data *training* maupun *testing*, metode *neural network* dapat melakukan peramalan lebih baik dibandingkan ARIMA berdasarkan kriteria RMSE, MAE,

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

Prilyandari Dina Saputri, Pratnya Paramitha Oktaviana

dan MAPE. Perbandingan data aktual dan ramalan menggunakan metode ARIMA dan *neural network* dapat ditunjukkan oleh Gambar 3.7.



Gambar 3.7. Perbandingan Data Aktual dan Ramalan Peramalan Piutang Kredit

Berdasarkan Gambar 3.7, dapat diketahui bahwa pada data *training*, hasil ramalan menggunakan ARIMA cenderung lebih lambat dalam menangkap pola perubahan tren. Pada data *testing*, model *neural network* juga cenderung lebih dapat menangkap pola data aktual yang ditandai dengan line plot berwarna hijau (*neural network*) lebih mendekati line plot berwarna hitam (pola data aktual). Dengan demikian, model *neural network* dapat meramalkan pemberian kredit oleh lembaga pembiayaan secara lebih baik dibandingkan model ARIMA.

Hasil analisis pada penelitian ini juga sejalan dengan penelitian sebelumnya yang menunjukkan bahwa metode *neural network* memiliki akurasi yang baik apabila dibandingkan dengan regresi linier berganda [3]–[5] maupun metode ARIMA [11]–[13]. Pada model *neural network* juga tidak diperlukan asumsi khusus dalam pembentukan modelnya, sehingga penggunaan metode *neural network* juga lebih fleksibel dibandingkan dengan metode statistika klasik. Berdasarkan hasil penelitian ini, model *neural network* yang telah terbentuk dapat digunakan untuk melakukan prediksi maupun peramalan khususnya dalam bidang finansial.

Prediksi serta peramalan yang akurat dapat dijadikan pedoman untuk mengambil kebijakan pada lembaga terkait. Prediksi NPL lembaga keuangan tentunya dapat mencerminkan tingkat risiko lembaga keuangan tersebut secara global. Prediksi tersebut juga dapat dilakukan untuk beberapa periode kedepan. Sehingga lembaga keuangan yang diprediksi akan mengalami NPL dapat dilakukan pengawasan secara lebih mendalam pada aspek aspek lainnya, seperti besarnya *delinquency*, besarnya debitur yang mengalami *write off*, dan indikator lainnya. Dengan demikian prediksi NPL ini juga dapat dijadikan sebagai *screening* awal kondisi suatu lembaga keuangan. Peramalan piutang kredit beberapa periode kedepan tentunya juga bermanfaat dalam mengambil kebijakan. Apabila terdapat tren menurun pada proyeksi piutang kredit, maka diperlukan stimulasi untuk meningkatkan pembiayaan kredit. Adanya tren menurun pada pemberian piutang kredit juga dapat meningkatkan potensi rasio kredit macet karena nilai *outstanding* yang menjadi lebih kecil. Dengan demikian, proyeksi yang akurat tentunya dapat dijadikan pedoman dalam menentukan stimulasi pemberian kredit.

4. KESIMPULAN

Implementasi *Feedforward Neural Network* pada prediksi NPL perbankan dan juga peramalan piutang kredit lembaga pembiayaan menunjukkan performa yang lebih baik dibandingkan dengan metode klasik seperti regresi linier berganda dan juga ARIMA. Perbandingan metode untuk prediksi NPL perbankan dilakukan berdasarkan nilai RMSE data *testing*, sedangkan pada peramalan piutang dilakukan berdasarkan nilai RMSE, MAE, dan MAPE data *testing*. Hasil analisis juga menunjukkan bahwa prediksi NPL perbankan juga dapat dilakukan berdasarkan data pada satu periode maupun dua periode sebelumnya. Bahkan nilai akurasi untuk dua periode

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI
Prilyandari Dina Saputri, Pratnya Paramitha Oktaviana

sebelumnya justru lebih baik. Dengan demikian untuk memprediksi NPL 2 periode kedepan dapat digunakan rasio rasio keuangan pada periode saat ini. Peramalan piutang kredit dari lembaga pembiayaan masih menunjukkan tren yang belum meningkat. Adanya tren yang menurun sejak pandemi pada Maret 2020 dapat ditangkap dengan baik oleh metode *neural network*.

DAFTAR PUSTAKA

- [1] Russell S. & Norvig P., 2021. *Artificial Intelligence: A Modern Approach*, 4th ed., New York: Pearson Education.
- [2] Sarle W. S., 1994. Neural Networks and Statistical Models, in *Annual SAS Users Group International Conference*, , pp. 1–13.
- [3] Shams S. R., Jahani A., Kalantary S., Moeinaddini M., & Khorasani N., 2021, The evaluation on artificial neural networks (ANN) and multiple linear regressions (MLR) models for predicting SO2 concentration, *Urban Climate*, vol. 37, p. 100837.
- [4] Özçelep Y., Sevgen S., & Samli R., 2020, A study on the hydrogen consumption calculation of proton exchange membrane fuel cells for linearly increasing loads: Artificial Neural Networks vs Multiple Linear Regression, *Renewable Energy*, vol. 156, pp. 570–578.
- [5] Kim M. K., Kim Y. S., & Srebric J., 2020, Predictions of electricity consumption in a campus building using occupant rates and weather elements with sensitivity analysis: Artificial neural network vs. linear regression, *Sustainable Cities and Society*, vol. 62, p. 102385.
- [6] Etli Y., Asirdizer M., Hekimoglu Y., Keskin S., & Yavuz A., 2019. Sex estimation from sacrum and coccyx with discriminant analyses and neural networks in an equally distributed population by age and sex, *Forensic Science International*, vol. 303, p. 109955.
- [7] Alunni V., Jardin P. du, Nogueira L., Buchet L., & Quatrehomme G., 2015. Comparing discriminant analysis and neural network for the determination of sex using femur head measurements, *Forensic Science International*, vol. 253, pp. 81–87.
- [8] Mohammadi F. *et al.*, 2021, Artificial neural network and logistic regression modelling to characterize COVID-19 infected patients in local areas of Iran, *Biomedical Journal*, vol. 44, no. 3, pp. 304–316.
- [9] Sanderson M., Bulloch A. G. M., Wang J. L., Williamson T., & Patten S. B., 2019. Predicting death by suicide using administrative health care system data: Can feedforward neural network models improve upon logistic regression models?, *Journal of Affective Disorders*, vol. 257, pp. 741–747.
- [10] Fei Y., Hu J., Gao K., Tu J., Li W., & Wang W., 2017, Predicting risk for portal vein thrombosis in acute pancreatitis patients: A comparison of radical basis function artificial neural network and logistic regression models, *Journal of Critical Care*, vol. 39, pp. 115–123.
- [11] Fanoodi B., Malmir B., & Jahantigh F. F., 2019. Reducing demand uncertainty in the platelet supply chain through artificial neural networks and ARIMA models, *Computers in Biology and Medicine*, vol. 113, p. 103415.
- [12] Gencer K. & Başçiftçi F., 2021. Time series forecast modeling of vulnerabilities in the android operating system using ARIMA and deep learning methods, *Sustainable Computing: Informatics and Systems*, vol. 30, p. 100515.
- [13] Suhermi N., Suhartono, Prastyo D. D., & Ali B., 2018. Roll motion prediction using a hybrid deep learning and ARIMA model, *Procedia Computer Science*, vol. 144, pp. 251–258.
- [14] Azayite F. Z. & Achchab S., 2016. Hybrid Discriminant Neural Networks for Bankruptcy Prediction and Risk Scoring, *Procedia Computer Science*, vol. 83, pp. 670–674.
- [15] Zhao Z., Xu S., Kang B. H., Kabir M. M. J., Liu Y., & Wasinger R., 2015. Investigation and improvement of multi-layer perceptron neural networks for credit scoring, *Expert Systems with Applications*, vol. 42, no. 7, pp. 3508–3516.

- [16] Sun X. & Lei Y., 2021. Research on financial early warning of mining listed companies based on BP neural network model, *Resources Policy*, vol. 73, p. 102223.
- [17] Tavana M., Abtahi A. R., Caprio D. Di, & Poortarigh M., 2018. An Artificial Neural Network and Bayesian Network model for liquidity risk assessment in banking, *Neurocomputing*, vol. 275, pp. 2525–2554.
- [18] Bank Indonesia, 2013. Peraturan Bank Indonesia Nomor 15/2/PBI/2013.
- [19] Barus A. C. & Erick, 2016. Analisis Faktor-Faktor yang Mempengaruhi Non Performing Loan pada Bank Umum di Indonesia, *Jurnal Wira Ekonomi Mikroskil*, vol. 6, no. 2, pp. 113–122.
- [20] Margaretha F. & Kalista V., 2016. Faktor yang Mempengaruhi Non Performing Loan pada Bank di Indonesia, *Jurnal Kesejahteraan Sosial Maret*, vol. 3, no. 1, pp. 65–80.
- [21] Kristian E. F. & Hartomo K. D., 2019. Peramalan Pertumbuhan Kredit Menggunakan Algoritma Arima, *Universitas Kristen Satya Wacana*.
- [22] Putri K. I., 2019. Pemodelan dan Peramalan Pertumbuhan Kredit dengan ARIMA, *Sekolah Tinggi Ilmu Ekonomi Perbanas*.
- [23] Suhartono, 2007. Feedforward Neural Network untuk Pemodelan Runtun Waktu, *Universitas Gajah Mada*.
- [24] Zhang G. P. & Qi M., 2005. Neural Network Forecasting for Seasonal and Trend Time Series, *European Journal of Operational Research*, pp. 501–514.