

Ensemble Backpropagation Neural Network Dalam Memprediksi Inflasi

Imelda Saluza*¹, Lastri Widya Astuti², Dhamayanti³, Evi Yulianti⁴

^{1,3,4}Program Studi Sistem Informasi Fakultas Ilmu Komputer

²Program Studi Teknik Informatika

Jalan Jend. Sudirman Km. 4 No.62 Palembang, Sumatera Selatan 30129

e-mail: *imeldasaluza@gmail.com, lastriwidya@uigm.ac.id, dhamayanti@uigm.ac.id,
eviyulianti@uigm.ac.id

Abstrak

Volatilitas ekonomi secara global yang terus menerus mengalami lonjakan menjadi perhatian khusus bagi negara-negara di dunia, termasuk Indonesia. Hal ini dikarenakan dampak yang akan terjadi jika terus menerus mengalami kenaikan yang dapat mengakibatkan terjadinya resesi perekonomian suatu negara. Suatu negara harus memperhatikan tekanan terhadap laju inflasi. Volatilitas laju inflasi yang tidak wajar dapat menyebabkan dampak negatif terhadap pertumbuhan ekonomi. Oleh karenanya, prediksi tingkat inflasi ke depan yang akurat sangat penting dilakukan agar menjadi informasi penting bagi pengambil kebijakan perekonomian. Prediksi inflasi menjadi salah satu masalah yang banyak diteliti dikarenakan data yang bersifat nonstasioner dan nonlinear sehingga dibutuhkan algoritma yang mampu mengatasi permasalahan tersebut. Salah satu algoritma yang dapat digunakan adalah Backpropagation Neural Network (BPNN), namun jaringan BPNN dalam penerapannya memiliki banyak parameter yang harus ditentukan sehingga sering menyebabkan terjadinya overfitting. Untuk itu alih-alih melakukan pembelajaran dari banyak model maka digunakanlah metode ensemble. Manfaat utama dari metode ini adalah mengurangi terjadinya overfitting serta menjaga akurasi dan keragaman jaringan BPNN secara bersamaan.

Kata kunci—*Volatilitas, Overfitting, Nonlinear, Nonstasioner.*

Abstract

Global economic volatility that continues to experience spikes is a particular concern for countries in the world, including Indonesia. This is due to the impact that will occur if it continues to increase which can result in a country's economic recession. A country must pay attention to the pressure on the inflation rate. Unreasonable inflation rate volatility can have a negative impact on economic growth. Therefore, it is very important to accurately predict future inflation rates so that it becomes important information for economic policy makers. Inflation prediction is one of the problems that has been widely researched because the data is non-stationary and non-linear, so an algorithm is needed that can overcome this problem. One of the algorithms that can be used is the Backpropagation Neural Network (BPNN), but the BPNN network in its application has many parameters that must be determined so that it often causes overfitting. For this reason, instead of learning from multiple models, the ensemble method is used. The main benefit of this method is to reduce overfitting and at the same time maintain the accuracy and diversity of the BPNN network.

Keywords—*Volatility, Overfitting, Nonlinear, Nonstationer.*

1. PENDAHULUAN

Volatilitas ekonomi global mengalami lonjakan yang cukup tinggi pada kuartal keempat di tahun 2022 [1]. Lonjakan harga pada sektor energi dan pangan yang disebabkan penurunan ketersediaan dari kedua komponen secara global. Krisis dari kedua komponen tersebut membuat banyak negara waspada terhadap tekanan inflasi dan juga terjadinya resesi. Kondisi perekonomian suatu negara menjadi cerminan keberhasilan jika mampu mengatasi permasalahan ekonomi. Salah satu faktor yang berpengaruh terhadap pertumbuhan ekonomi adalah inflasi. Jika inflasi suatu negara berada dalam tingkat wajar maka akan berdampak positif terhadap pertumbuhan ekonomi demikian sebaliknya. Inflasi menunjukkan kondisi dimana harga barang meningkat luas dan mempengaruhi harga barang lainnya atau dengan kata lain kenaikan harga barang akibat dinamika harga inflasi menyebabkan penurunan daya beli masyarakat. Inflasi akan terjadi jika jumlah uang yang beredar lebih banyak dibandingkan dengan persediaan barang yang dijual di pasaran. Kontrol terhadap jumlah uang yang beredar sangat penting dilakukan dalam pengendalian pertumbuhan perekonomian. Control financial dalam pertumbuhan ekonomi nasional sangat dibutuhkan terutama dalam jangka waktu menengah dan panjang. Tanpa kontrol tersebut maka pengendalian terhadap pertumbuhan ekonomi akan sangat sulit dilakukan apalagi lonjakan inflasi yang dapat mengakibatkan instabilitas pertumbuhan ekonomi.

Perkembangan pertumbuhan ekonomi di Indonesia mengalami perubahan, berdasarkan dari data Badan Pusat Statistik (BPS) pertumbuhan ekonomi di Indonesia tahun 2020 dibanding 2019 mengalami pertumbuhan sebesar 2,07% [2]. Pertumbuhan ekonomi adalah Pendapatan Domestik Bruto dengan asumsi menyampingkan faktor peningkatan dan penurunan jumlah pertumbuhan penduduk [3]. Secara mengejutkan International Monetary Fund memotong proyeksi pertumbuhan ekonomi global menjadi 2,9% pada tahun 2023, hal ini berakibat akan banyak negara yang mengalami kesusahan untuk mendapatkan belanja negara serta pengelolaan pembiayaan. Yang berakibat pada terjadinya inflasi dan berkorelasi terhadap terjadinya resesi ekonomi. Resesi perekonomian secara global dilatar belakangi oleh beberapa hal, antara lain adalah dampak terjadinya pandemi covid-19, konflik Ukraina -Rusia dan inflasi. Indonesia sebagai bagian dari negara di dunia dan juga termasuk negara berkembang maka sudah seharusnya menyiapkan diri dalam menghadapi ancaman resesi.

Adanya volatilitas terhadap tingkat inflasi menyebabkan perlunya dilakukan prediksi tingkat inflasi yang akan terjadi pada beberapa waktu ke depan. Prediksi tersebut diharapkan akan menjadi informasi bagi pemerintah dalam mencegah ancaman resesi sehingga pemerintah akan menjadi lebih berhati-hati dalam menetapkan kebijakan perekonomian agar dapat memperkecil dampak resesi global 2023. Prediksi volatilitas lonjakan inflasi merupakan permasalahan yang menarik dan juga menantang. Beberapa penelitian telah dilakukan untuk memprediksi tingkat inflasi antara lain, [4] memprediksi inflasi bulanan Amerika Serikat; [5] memprediksi inflasi bulanan Australia dan [5] memprediksi tingkat inflasi Filipina selama lima tahun ke depan (2019 – 2023).

Tingkat inflasi dalam kenyataannya sering mengalami lonjakan-lonjakan yang mengakibatkan sulitnya dilakukan prediksi. Lonjakan tersebut menunjukkan adanya volatilitas data yang menyebabkan data inflasi cenderung memiliki pola non linear dan non stasioner. Kedua sifat data tersebut menjadi tantangan bagi banyak peneliti untuk melakukan prediksi. Karena karakteristik data non linear dan non stasioner menyebabkan banyak peneliti menggunakan kecerdasan buatan dalam melakukan prediksi. Kecerdasan buatan yang banyak digunakan dalam memprediksi data time series antara lain adalah Artificial Neural Network (ANN) [4], Support Vector Machines (SVM) [6] dan sebagainya. Karena keunggulan dari pendekatan kecerdasan buatan maka penelitian ini akan menggunakan ANN dalam melakukan prediksi data time series tingkat inflasi.

Dalam penerapannya ANN memiliki tantangan dalam hal overfitting. Pelatihan jaringan dilakukan terus menerus dengan merubah arsitektur dari jaringan ANN yang digunakan,

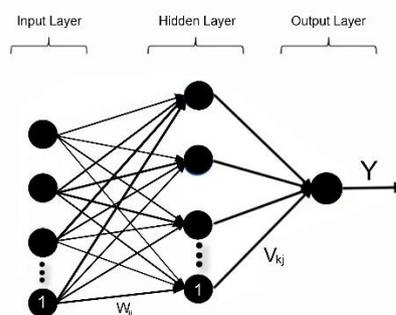
perubahan tersebut lebih banyak dilakukan dengan cara trial and error. Cara inilah yang menyebabkan jaringan yang dilatih mengalami overfitting. Overfitting sering terjadi pada ANN, hal ini disebabkan jaringan pada ANN telah sering dilatih untuk mendapatkan kinerja yang optimal. Karenanya pada penelitian ini akan dilakukan pendekatan ensemble yaitu dengan cara menggunakan satu metode pemodelan kemudian menggabungkan hasil masing-masing prediksi dengan terlebih dahulu melakukan subsampling terhadap data yang akan digunakan.

Banyak peneliti yang telah menggunakan metode ensemble untuk meningkatkan akurasi peramalan. Beberapa hasil penelitian menunjukkan bahwa metode ensemble dalam penerapannya mampu [7] memberikan peningkatan yang signifikan dibandingkan dengan hasil prediksi jaringan individu, [8] menyatakan bahwa ensemble di semua inialisasi pelatihan NN untuk model yang sama dapat meningkatkan akurasi bersamaan dengan menghilangkan kebutuhan untuk mengidentifikasi dan memilih inialisasi pelatihan terbaik, [9] menyatakan bahwa ensemble dengan menggabungkan output dari beberapa jaringan anggota sehingga mampu mengontrol kesalahan generalisasi lebih baik daripada jaringan individu, serta hasil penelitian [10] menunjukkan bahwa error hasil peramalan menggunakan metode ensemble secara signifikan lebih rendah daripada jaringan Neural Network individual. Dalam banyak penelitian menyatakan bahwa belum adanya metode langsung yang dapat digunakan dalam memilih parameter sehingga perancang harus bergantung pada pengetahuan atau dilakukan dengan metode empiris. Kinerja NN dalam ensemble bergantung pada beberapa faktor antara lain adalah topologi NN dan struktur awal, metode pelatihan, isi dari sampel pelatihan [11]. Karenanya pada penelitian ini akan melakukan ensemble dengan menggunakan topologi, data training dan struktur awal yang berbeda dalam pembangkitan jaringan individual dan dilanjutkan dengan ensemble NN dari pembangkitan jaringan individual tersebut.

2. METODE PENELITIAN

2.1 Neural Network

Artificial Neural Network (ANN) merupakan algoritma yang prinsip dan fungsinya menyerupai otak manusia [12]. Struktur jaringan NN terdiri dari tiga lapisan yaitu input, hidden dan output. Setiap lapisan memiliki sejumlah neuron yang berfungsi untuk menghubungkan antar lapisan dan disertai dengan bobot. Bobot jaringan dihitung secara iteratif dalam proses pelatihan. Pembelajaran didapatkan dengan menyesuaikan bobot sampai kriteria yang diinginkan telah tercapai yaitu dengan memetakan non linieritas antara lapisan input dan output [13]. Salah satu algoritma NN yang sering digunakan adalah *Backpropagation Neural Network* (BPNN), pada penelitian ini akan menggunakan BPNN dalam melatih jaringan individual, untuk struktur jaringan terlihat pada gambar berikut. BPNN dalam penerapannya telah banyak digunakan untuk memprediksi data time series. Arsitektur jaringan dari BPNN terdiri dari tiga lapisan, seperti gambar berikut.



Gambar 1. Struktur Jaringan BPNN

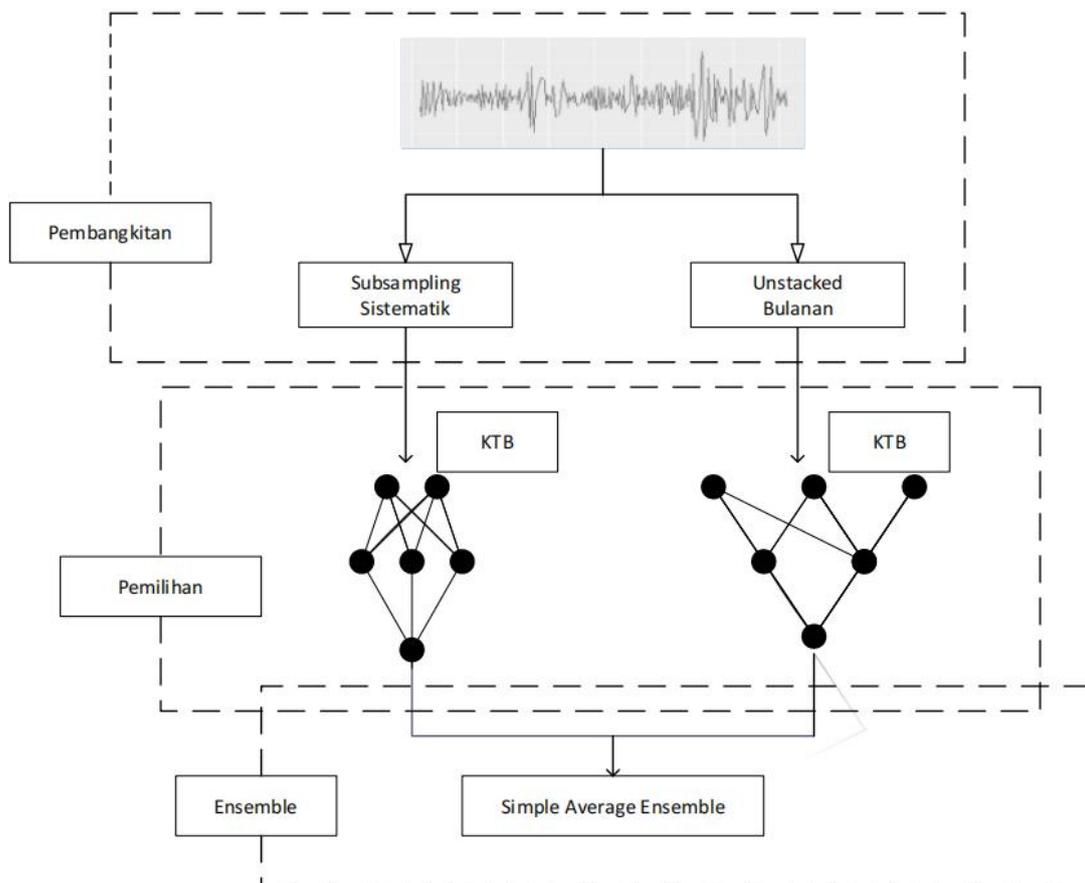
Menurut [14] prosedur pembelajaran dari BPNN dijelaskan berdasarkan langkah-langkah berikut:

- Langkah 1 : Normalisasi data input, dan sajikan data input ke lapisan input
- Langkah 2 : Tentukan arsitektir jaringan dan parameter-parameter yang akan digunakan seperti fungsi aktivasi, learning rate, momentum, bobot awal
- Langkah 3 : Hitung error pada neuron ouput dengan membandingkan ouput yang dihasilkan dengan output target
- Langkah 4 : Hitung perubahan bobot menggunakan error untuk menghitung perubahan bobot antara lapisan hidden dan output
- Langkah 5 : Perbarui bobot
- Langkah 6 : Ulangi langkah 1-5 hingga error global satifies e predifines threshold

Masalah dari algoritma BPNN adalah penentuan parameter-parameter yang akan digunakan pada algoritma tersebut. Banyak penelitian yang melakukan dengan menggunakan uji coba, namun beberapa penelitian telah memberikan beberapa pendekatan untuk menentukannya. Pengulangan beberapa kali dari algoritma BPNN akan meningkatkan akurasi namun akibatnya meningkatkan komputasi.

2. 2 Rancangan Ensemble

Ensemble mencoba untuk menghasilkan output yang handal dan akurat dengan mengintegrasikan sejumlah jaringan individual yang telah dilatih dibandingkan hanya memilih jaringan individual yang terbaik. Penelitian ini menggunakan ensemble dalam memprediksi tingkat inflasi Indonesia dan rancangan pengembangan ensemble disajikan pada gambar berikut.



Gambar 2. Proses Perancangan Ensemble

Gambar 2 menunjukkan tahapan ensemble neural network yang dikembangkan yang terdiri dari tiga tahapan pembelajaran ensemble. Tahapan tersebut adalah pembangkitan, pemilihan dan ensemble. Tahapan pembangkitan terdiri dari dua teknik sampling yaitu subsampling yang dilakukan secara sistematis dan unstacked bulanan dari data time series aktual. Selanjutnya adalah pemilihan yang menggunakan *Keep the Best* (KTB) dan terakhir akan dilakukan proses ensemble dengan menggunakan strategi *Simple Average Ensemble*.

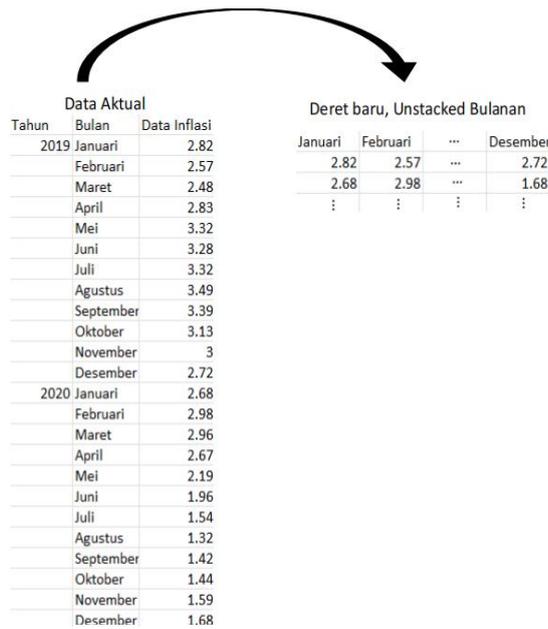
Secara umum, struktur jaringan individual yang berbeda kemudian diintegrasikan mampu mengurangi error pada sampel pelatihan yang berbeda sehingga kinerja akhir model akan maksimal. Tujuan dari pengembangan model adalah untuk mengatasi permasalahan overfitting dengan cara menemukan jaringan-jaringan individual yang memberikan kinerja jaringan terbaik akan dipilih dan digunakan untuk dilakukan ensemble dengan menggunakan strategi *Simple Average Ensemble*. Strategi yang digunakan agar memperoleh efek prediksi yang efektif.

Secara khusus, penelitian ini akan merancang topologi jaringan individual. Menemukan topologi yang benar adalah masalah utama dalam perancangan arsitektur jaringan individual [15]. Untuk merancang jaringan perlu untuk menentukan beberapa parameter yang akan digunakan, seperti jumlah lapisan, jumlah neuron untuk setiap lapisan, fungsi aktivasi dan derajat konektivitas. Parameter awal yang akan dirancang pada penelitian ini adalah memvariasikan input pelatihan yang berbeda dengan melakukan subsampling sistematis seperti gambar berikut [16].

Tabel 1. Gambaran Subsampling Sistematis

Subsampel1		
Kasus	Input	Target
1	$X_{1,1} = (x_1, x_2, x_3)$	$y_{1,1} = x_4$
2	$X_{2,1} = (x_4, x_5, x_6)$	$y_{2,1} = x_7$
⋮		
$t/3$	$X_{t/3,1} = (x_{t-5}, x_{t-4}, x_{t-3})$	$y_{t/3,1} = x_{t-2}$
Subsampel2		
Kasus	Input	Target
1	$X_{1,2} = (x_2, x_3, x_4)$	$y_{1,2} = x_5$
2	$X_{2,2} = (x_5, x_6, x_7)$	$y_{2,2} = x_8$
⋮		
$t/3$	$X_{t/3,2} = (x_{t-4}, x_{t-3}, x_{t-2})$	$y_{t/3,2} = x_{t-1}$
Subsampel3		
Kasus	Input	Target
1	$X_{1,3} = (x_3, x_4, x_5)$	$y_{1,3} = x_6$
2	$X_{2,3} = (x_6, x_7, x_8)$	$y_{2,3} = x_9$
⋮		
$t/3$	$X_{t/3,3} = (x_{t-3}, x_{t-2}, x_{t-1})$	$y_{t/3,3} = x_t$

Tabel 1 menunjukkan subsampling sistematis yang akan digunakan dalam penelitian ini untuk membagi data time series menjadi sub-sub sampling yang dilakukan secara sistematis. Selanjutnya dalam juga akan digunakan unstacked bulanan dari data time series seperti gambar berikut [17].



Gambar 3. Unstacked Bulanan

Setelah proses variasi input dilanjutkan dengan merancang jumlah neuron lapisan hidden yang digunakan. Pemilihan jumlah neuron yang akan digunakan untuk melatih jaringan individual merupakan salah satu permasalahan yang penting untuk mengurangi terjadinya overfitting akibat pelatihan yang terus menerus. Beberapa waktu terakhir telah banyak perkembangan penelitian dalam menentukan jumlah neuron pada lapisan hidden. Seperti [18]

mengusulkan persamaan $\frac{3N_i}{(N_i+6)}$ dan hasil evaluasi menunjukkan kinerja jaringan menjadi lebih baik; [19] menggunakan formula $\frac{\sqrt{N_i+N_o}}{2}$ dalam meramalkan kecepatan angin, berdasarkan penelitiannya diperoleh peningkatan akurasi peramalan; dan [20] menggunakan

persamaan $\left(\frac{3\sqrt{N_i}}{\sqrt{N_o}}\right)^2$ dan hasilnya memberikan rekomendasi praktis dalam menguji sampel data serta mampu menghemat waktu pelatihan jaringan.

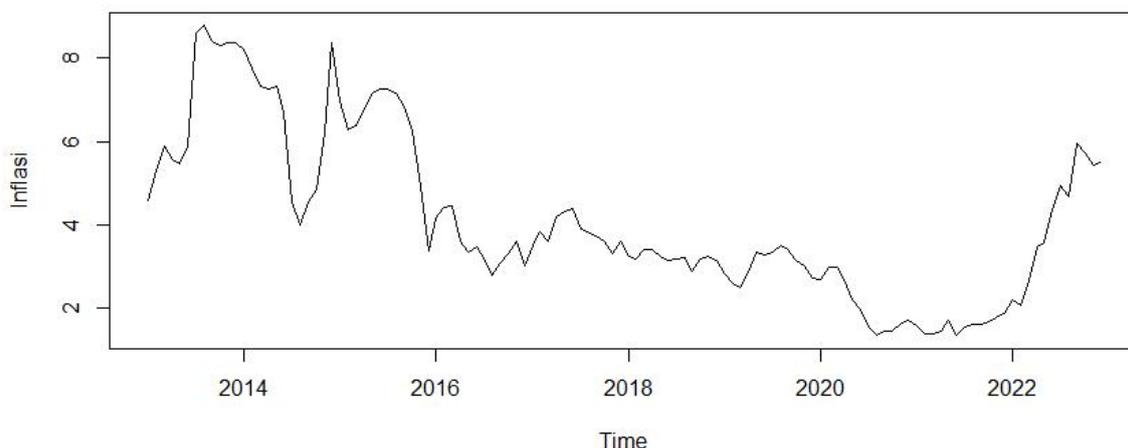
Setelah jaringan-jaringan individual dibangkitkan maka selanjutnya dipilih jaringan individual yang memberikan kinerja optimum dengan memperhatikan nilai error yang dihasilkan. Berdasarkan nilai error tersebut maka jaringan individual akan dipilih menggunakan pendekatan *KTB*. Setelah jaringan individual terpilih maka langkah terakhir adalah menerapkan strategi ensemble dengan *Simple Average Ensemble*. Menurut [16] dalam beberapa percobaan telah menunjukkan bahwa simple averaging merupakan pendekatan yang efektif dan dapat meningkatkan kinerja jaringan syaraf. Pendekatan ini bermanfaat jika anggota ansambel memiliki minimum lokal yang berbeda-beda. Minimum lokal yang berbeda sama artinya bahwa anggota ansambel beragam.

3. HASIL DAN PEMBAHASAN

Efektifitas kinerja ensemble backpropagation neural network akan diverifikasi pada masalah data time series inflasi di Indonesia. Pelatihan dilakukan pada data dengan pengaturan parameter yang bervariasi dari jaringan individual dan kemudian akan dilihat nilai error yang dihasilkan. Proses pelatihan jaringan individual menggunakan algoritma BPNN [21]. Fungsi aktivasi yang digunakan antara lapisan input dan hidden adalah tansig dan untuk hidden ke output purelin, sedangkan bobot awal diambil secara acak.

3.1. Data Penelitian

Data yang akan diprediksi pada penelitian ini adalah jenis data time series. Data tersebut adalah data time series dari laju inflasi bulanan di Indonesia selama sepuluh tahun terakhir mulai dari tahun 2013 s.d 2023 dan data tersebut diperoleh dari website Bank Indonesia. Dan data tersebut disajikan pada gambar berikut.



Gambar 3. Plot Data Aktual Inflasi Indonesia

berdasarkan gambar 1 terlihat bahwa data inflasi memiliki volatilitas data dimana terdapat lonjakan-lonjakan seperti tahun 2013 sampai dengan 2016 dan di tahun 2022 mengalami lonjakan data kembali. Selanjutnya dilakukan analisis deskriptif dari data inflasi, diperoleh hasil bahwa data inflasi tertinggi di Indonesia sebesar 8.79% dan terendah sebesar 1.32% sedangkan rata-rata inflasi setiap bulannya adalah 4.114%.

Tabel 2. Statistik Deskriptif Data Inflasi

Minimum	Median	Mean	Maximum
1.320	3.480	4.114	8.790

3.2. Hasil Empiris

Bagian ini membahas hasil empiris dari efektivitas metode ensemble BPNN. Sebelum dilakukan penentuan parameter arsitektur jaringan individual, data aktual akan dilakukan cross validasi dengan menggunakan pembagian 70% data training dan sisanya data testing atau sebesar 84 data training dan sebanyak 36 data untuk data testing. Kinerja jaringan diukur menggunakan MSE dan MAE.

Tabel 3. Perbandingan Kinerja Metode Ensemble dan Jaringan Individual

Keep The best							
Pembangkitan	Neuron Hidden	Epoch	Training		Epoch	Testing	
			MSE	MAE		MSE	MAE
Subsampling Sistematis	1	145	0.0306	0.1208	12	0.0192	0.0994
	2	142	0.0308	0.1187	104	0.0190	0.0981
	3	67	0.0308	0.1190	120	0.0190	0.0979
Unstacked Bulanan	1	361	0.0194	0.0960	184	0.0515	0.1796
	2	64	0.0188	0.0947	96	0.0515	0.1812
	3	172	0.0218	0.0976	31	0.0516	0.1821
Ensemble							
Pembangkitan	Neuron Hidden	Epoch	Training		Epoch	Testing	
			MSE	MAE		MSE	MAE
Subsampling	1	78	0.0276	0.1100	57	0.0135	0.0676

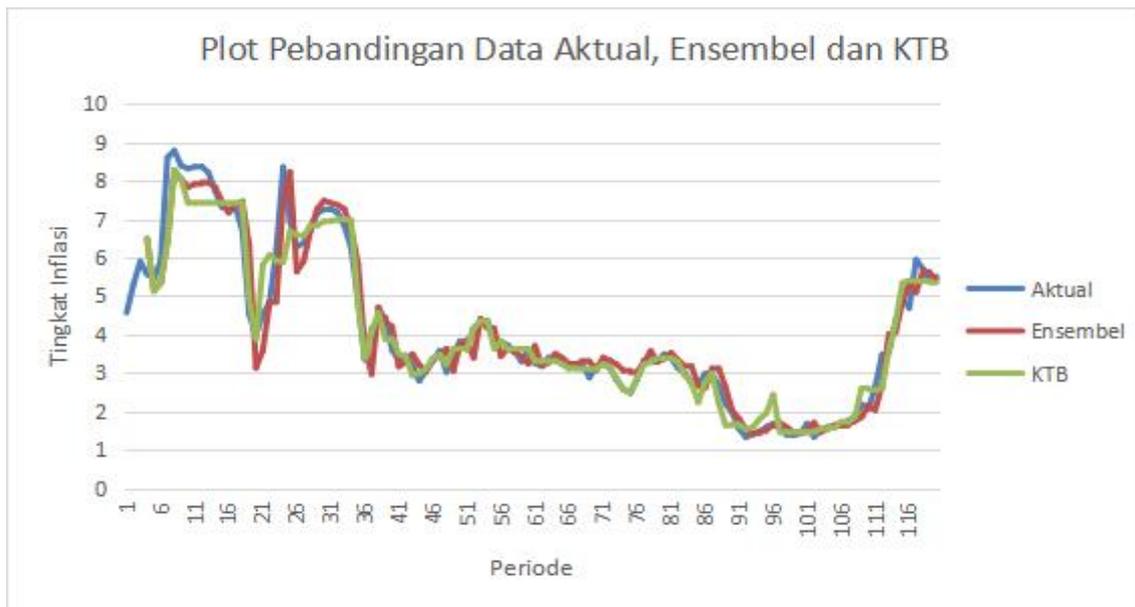
Sistematik	2	90	0.0265	0.1198	104	0.0100	0.0819
	3	65	0.0254	0.1190	120	0.0190	0.0779
Unstacked Bulanan	1	75	0.0097	0.0677	104	0.0078	0.0564
	2	102	0.0108	0.0713	78	0.0074	0.0551
	3	99	0.0111	0.0714	56	0.0074	0.0521

Tabel 3 menjelaskan hasil rinci dari metode ensemble untuk data training dan testing. Terlihat bahwa pembangkitan data yang digunakan dengan jumlah neuron lapisan hidden berbeda yaitu 1, 2, dan 3 yang merupakan arsitektur jaringan individual diperoleh jumlah epoch dan nilai error dari data training dan testing. Berdasarkan hasil pengolahan data yang disajikan untuk jaringan tunggal yang dilatih dan dipilih menggunakan KTB diperoleh bahwa data yang dibangkitkan dengan unstacked bulanan memberikan kinerja jaringan yang baik dibandingkan pembangkitan menggunakan subsampling sistematik untuk data training dan data testing. Dari tabel juga terlihat bahwa ada kinerja jaringan yang saat dilatih memberikan kinerja baik sedangkan ketika diuji malah sebaliknya. Hal ini menunjukkan bahwa jaringan mengalami overfitting yang sangat sering terjadi pada jaringan NN. Sedangkan data yang telah dilakukan strategi ensemble memberikan hasil yang lebih baik dibandingkan dengan jaringan tunggal.

Pada pembangkitan jaringan individual dilakukan pengulangan sebanyak lima kali sehingga jaringan yang memberikan kinerja terbaik akan dipilih menggunakan KTB, sedangkan untuk ensemble jaringan yang telah dilatih tadi akan dilakukan strategi ensemble untuk melai jaringan-jaringan individual. Berdasarkan hasil pengolahan data diperoleh bahwa kinerja jaringan menggunakan metode ensemble membeikan hasil yang lebih baik pada data training dan testing.

Secara keseluruhan dapat disimpulkan bahwa metode ensemble lebih baik digunakan dibandingkan hanya menggunakan jaringan individual yang dipilih menggunakan KTB karena dapat menyebabkan overfitting pada jaringan tersebut, dan pembangkitan dengan menggunakan unstacked bulanan memberikan hasil kinerja yang lebih optimal dibandingkan subsampling sistemati. Hal ini dikarenakan penggunaan subsampling sistematik menyebabkan terjadinya autokorelasi antar data yang digunakan sedangkan penggunaan unstacked memberikan hasil prediksi yang tidak berkorelasi sehingga mampu memperbaiki hasil prediksi.

Selanjutnya hasil prediksi menggunakan metode ensemble dengan NN individual dan data aktual dari laju inflasi.



Gambar 4. Plot Pebandingan Prediksi

Gambar 4 menunjukkan plot perbandingan antara hasil prediksi menggunakan metode ensemble dan NN individual dengan data aktual. terlihat bahwa hasil prediksi laju inflasi menggunakan metode ensemble mampu mengungguli kinerja jaringan individual yang dipilih menggunakan KTB. Berdasarkan hasil ini maka dapat diprediksi tingkat inflasi Indonesia beberapa waktu ke depan.

Tabel 4. Prediksi Nilai Inflasi Beberapa Waktu ke Depan

Periode	Prediksi
Januari 2023	5.83
Februari 2023	4.30
Maret 2023	2.03

4. KESIMPULAN

Prediksi yang akurat dari laju inflasi ke depan sangat penting sebagai informasi serta proyeksi bagi pengambil keputusan perekonomian. Karakteristik data inflasi yang nonstasioner dan nonlinearitas menyebabkan digunakannya algoritma *Backpropagation Neural Network* (BPNN). Dalam penerapannya BPNN memiliki banyak parameter yang harus di tentukan untuk mendapatkan arsitektur yang memiliki kinerja optimal. Parameter tersebut antara lain jumlah neuron lapisan input dan lapisan hidden, fungsi aktivasi, bobot awal yang digunakan. Penentuan parameter sering dilakukan menggunakan cara *trial and error*. Akibat dari cara tersebut adalah jaringan yang dilatih mengalami overfitting atau jaringan menjadi cenderung menghafal. Untuk mengatasi permasalahan tersebut dilakukan teknik ensemble dengan menggabungkan jaringan-jaringan individual yang telah dilatih dan memberikan kinerja yang optimum.

5. SARAN

Penelitian ini menggunakan metode ensemble yang terdiri dari tiga tahapan yaitu pembangkitan, pemilihan dan penggabungan. Pembangkitan dilakukan dengan menggunakan variasi terhadap neuron lapisan input dan lapisan hidden, fungsi aktivasi dan bobot awal. Pemilihan menggunakan teknik *Keep the Best* dan penggabungan menggunakan *Simple Average Method*. Namun banyak metode yang dapat digunakan dalam setiap tahapannya, sehingga peneliti selanjutnya dapat menggunakan teknik yang berbeda.

DAFTAR PUSTAKA

- [1] Y. R. T. Hutagaol, R. P. P. Sinurat, and S. M. Shalahuddin, "Strategi Penguatan Keuangan Negara Dalam Menghadapi Ancaman Resesi Global 2023 Melalui Green Economy," *J. Pajak dan Keuang. Negara*, vol. 4, no. 1S, pp. 378–385, 2022, doi: 10.31092/jpkn.v4i1s.1911.
- [2] I. Restiasanti and I. Yuliana, "Pengaruh Inflasi Dan Nilai Tukar Terhadap Pertumbuhan Ekonomi Dengan Penerimaan Pajak Sebagai Variabel Moderasi," *Al-Kharaj J. Ekon. Keuang. Bisnis Syariah*, vol. 5, no. 1, pp. 285–302, 2022, doi: 10.47467/alkharaj.v5i1.1203.
- [3] H. H. Alwi and L. Nirawati, "Pengaruh Inflasi, Suku Bunga Bank Indonesia, dan Nilai Tukar Rupiah (USD/IDR) terhadap Indeks Saham Bisnis-27 di Bursa Efek Indonesia (BEI)," *Al-Kharaj J. Ekon. Keuang. Bisnis Syariah*, vol. 5, no. 2, pp. 620–635, 2022, doi: 10.47467/alkharaj.v5i2.1242.
- [4] A. Almosova and N. Andresen, "Nonlinear inflation forecasting with recurrent neural networks," *J. Forecast.*, no. January 2022, pp. 240–259, 2022, doi: 10.1002/for.2901.
- [5] G. Moser, F. Rumler, and J. Scharler, "Forecasting Austrian Inflation," no. 91, 2004.
- [6] B. Zhu, S. Ye, P. Wang, J. Chevallier, and Y. M. Wei, "Forecasting carbon price using a multi-objective least squares support vector machine with mixture kernels," *J. Forecast.*,

- vol. 41, no. 1, pp. 100–117, 2022, doi: 10.1002/for.2784.
- [7] K. Siwek, S. Osowski, and R. Szupiluk, “Ensemble neural network approach for accurate load forecasting in a power system,” *Int. J. Appl. Math. Comput. Sci.*, vol. 19, no. 2, pp. 303–315, 2009, doi: 10.2478/v10006-009-0026-2.
- [8] U. Naftaly, N. Intrator, and D. Horn, “Optimal ensemble averaging of neural networks,” *Netw. Comput. Neural Syst.*, vol. 8, no. 3, pp. 283–296, 1997, doi: 10.1088/0954-898x/8/3/004.
- [9] D. Il Jeong and Y. O. Kim, “Rainfall-runoff models using artificial neural networks for ensemble streamflow prediction,” *Hydrol. Process.*, vol. 19, no. 19, pp. 3819–3835, 2005, doi: 10.1002/hyp.5983.
- [10] P. Melin, J. C. Monica, D. Sanchez, and O. Castillo, “Multiple ensemble neural network models with fuzzy response aggregation for predicting covid-19 time series: The case of mexico,” *Healthc.*, vol. 8, no. 2, 2020, doi: 10.3390/healthcare8020181.
- [11] Y. Liu, X. Yao, and T. Higuchi, “Evolutionary ensembles with negative correlation learning,” *IEEE Trans. Evol. Comput.*, vol. 4, no. 4, pp. 380–387, 2000, doi: 10.1109/4235.887237.
- [12] S. Sobri, S. Koohi-Kamali, and N. A. Rahim, “Solar photovoltaic generation forecasting methods: A review,” *Energy Convers. Manag.*, vol. 156, no. May 2017, pp. 459–497, 2018, doi: 10.1016/j.enconman.2017.11.019.
- [13] S. I. Vagropoulos, E. G. Kardakos, C. K. Simoglou, A. G. Bakirtzis, and J. P. S. Catalão, “ANN-based scenario generation methodology for stochastic variables of electric power systems,” *Electr. Power Syst. Res.*, vol. 134, pp. 9–18, 2016, doi: 10.1016/j.epsr.2015.12.020.
- [14] S. K. Purohit, S. Panigrahi, P. K. Sethy, and S. K. Behera, “Time Series Forecasting of Price of Agricultural Products Using Hybrid Methods,” *Appl. Artif. Intell.*, vol. 35, no. 15, pp. 1388–1406, 2021, doi: 10.1080/08839514.2021.1981659.
- [15] K. M. R. Alam, N. Siddique, and H. Adeli, “A dynamic ensemble learning algorithm for neural networks,” *Neural Comput. Appl.*, vol. 32, no. 12, pp. 8675–8690, 2020, doi: 10.1007/s00521-019-04359-7.
- [16] G. Zang, V. Berardi, and Z. Reitermanová, “Time series forecasting with neural network ensembles: An application for exchange rate prediction,” *J. Oper. Res. Soc.*, no. 52, pp. 652–664, 2010, [Online]. Available: https://www.mff.cuni.cz/veda/konference/wds/proc/pdf10/WDS10_105_i1_Reitermanova.pdf.
- [17] M. O. Moreira, P. P. Balestrassi, A. P. Paiva, P. F. Ribeiro, and B. D. Bonatto, “Design of experiments using artificial neural network ensemble for photovoltaic generation forecasting,” *Renew. Sustain. Energy Rev.*, vol. 135, no. September 2020, p. 110450, 2021, doi: 10.1016/j.rser.2020.110450.
- [18] A. Meng, J. Ge, H. Yin, and S. Chen, “Wind speed forecasting based on wavelet packet decomposition and artificial neural networks trained by crisscross optimization algorithm,” *Energy Convers. Manag.*, vol. 114, pp. 75–88, 2016, doi: 10.1016/j.enconman.2016.02.013.
- [19] J. Wang and J. Hu, “A robust combination approach for short-term wind speed forecasting and analysis - Combination of the ARIMA (Autoregressive Integrated Moving Average), ELM (Extreme Learning Machine), SVM (Support Vector Machine) and LSSVM (Least Square SVM) forecasts used,” *Energy*, vol. 93, pp. 41–56, 2015, doi: 10.1016/j.energy.2015.08.045.
- [20] I. Saluza and L. D. Anggraini, “BPNN ’ s Empirical Analysis of Daily Rupiah Exchange Rate Volatility Utilizing,” *J. AKSI Akunt. dan Sist. Inf.*, vol. 7, no. 1, pp. 41–51, 2022.
- [21] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning representations by back-propagating errors,” *Nature*, vol. 323, no. 6088, pp. 533–536, 1986, doi: 10.1038/323533a0.