

PREDIKSI INFLASI INDONESIA BERDASARKAN FUZZY ANN MENGGUNAKAN ALGORITMA GENETIKA

Anwar Rifa'i

Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Universitas Budi Luhur, Jakarta, Indonesia
e-mail: anwar.rifai@budiluhur.ac.id

Diterima: 7 Juni 2020 – Direvisi: 27 Juli 2020 – Disetujui: 4 Agustus 2020

ABSTRACT

Monetary policy makers have a fear of inflation because it can trigger an increase in poverty and soaring budget uses. A high level of inflation will result in a country's economic collapse. Monetary policy making needs to be studied to prevent this. One effort that can be done is to predict the inflation that will occur. Inflation rate time series data can be used to predict future inflation rates. Pemangku kebijakan moneter memiliki ketakutan terhadap inflasi karena dapat memicu naiknya angka kemiskinan dan melonjaknya penggunaan anggaran. Tingkat Inflasi yang tinggi akan mengakibatkan jatuhnya perekonomian suatu negara. Pengambilan kebijakan moneter perlu dikaji secara mendalam untuk mencegah hal tersebut. Salah satu upaya yang dapat dilakukan adalah dengan melakukan prediksi inflasi yang akan terjadi. Data tingkat inflasi dari waktu ke waktu merupakan modal untuk melakukan prediksi tingkat inflasi pada waktu mendatang. Suatu prediksi yang baik memiliki nilai error yang kecil. Pada prediksi menggunakan fuzzy artificial neural network (Fuzzy ANN) metode backpropagation, nilai error dapat diperkecil dengan melakukan optimasi pada bobot yang dihasilkan. Pada penelitian ini, optimasi bobot Fuzzy ANN dilakukan menggunakan algoritma genetika. Model prediksi yang diperoleh selanjutnya dievaluasi menggunakan MAPE untuk menentukan keakuratan prediksi. Hasil penelitian menunjukkan bahwa prediksi menggunakan backpropagation neural network dioptimasi menggunakan algoritma genetika (10,33%) lebih baik dibandingkan dengan prediksi menggunakan backpropagation neural network saja (11,67%). Setelah mengetahui bahwa kedua model memiliki hasil prediksi yang cukup baik, keakuratan kedua model dibandingkan menggunakan independent sample t-test berdasarkan error yang dihasilkan. Hasilnya menunjukkan bahwa pada tingkat kepercayaan 95% prediksi menggunakan Fuzzy ANN yang telah dioptimasi menggunakan algoritma genetika ($M= 0,69$, $SD= 0,0421$) lebih baik secara signifikan dibandingkan dengan fuzzy ANN saja ($M= 0,97$, $SD= 0,04634$), $t(22) = 1.71714$, $p=0.013$.

Keywords: Backpropagation, Genetic Algorithm, Inflation, Neural Network, Prediction.

ABSTRAK

Pemangku kebijakan moneter memiliki ketakutan terhadap inflasi karena dapat memicu naiknya angka kemiskinan dan melonjaknya penggunaan anggaran. Tingkat Inflasi yang tinggi akan mengakibatkan jatuhnya perekonomian suatu negara. Pengambilan kebijakan moneter perlu dikaji secara mendalam untuk mencegah hal tersebut. Salah satu upaya yang dapat dilakukan adalah dengan melakukan prediksi inflasi yang akan terjadi. Data tingkat inflasi dari waktu ke waktu merupakan modal untuk melakukan prediksi tingkat inflasi pada waktu mendatang. Suatu prediksi yang baik memiliki nilai error yang kecil. Pada prediksi menggunakan fuzzy artificial neural network (Fuzzy ANN) metode backpropagation, nilai error dapat diperkecil dengan melakukan optimasi pada bobot yang dihasilkan. Pada penelitian ini, optimasi bobot Fuzzy ANN dilakukan menggunakan algoritma genetika. Model prediksi yang diperoleh selanjutnya dievaluasi menggunakan MAPE untuk menentukan keakuratan prediksi. Hasil penelitian menunjukkan bahwa prediksi menggunakan backpropagation neural network dioptimasi menggunakan algoritma genetika (10,33%) lebih baik dibandingkan dengan prediksi menggunakan backpropagation neural network saja (11,67%). Setelah mengetahui bahwa kedua model memiliki hasil prediksi yang cukup baik, keakuratan kedua model dibandingkan menggunakan independent sample t-test berdasarkan error yang dihasilkan. Hasilnya menunjukkan bahwa pada tingkat kepercayaan 95% prediksi menggunakan Fuzzy ANN yang telah dioptimasi menggunakan algoritma genetika ($M= 0,69$, $SD= 0,0421$) lebih baik secara signifikan dibandingkan dengan fuzzy ANN saja ($M= 0,97$, $SD= 0,04634$), $t(22) = 1.71714$, $p=0.013$.

Kata Kunci: Algoritma Genetika, Backpropagation, Inflasi, Neural Network, Prediksi.

I. PENDAHULUAN

INFLASI dan efeknya pada perekonomian suatu negara merupakan salah satu isu yang paling banyak didiskusikan dalam perekonomian makro [1]. Inflasi terjadi saat harga-harga mengalami kenaikan secara terus menerus dalam waktu tertentu. Kenaikan ini tidak hanya terjadi pada salah satu jenis barang saja namun secara masal pada berbagai barang. Tingginya inflasi dapat menyebabkan ketidakstabilan pada ekonomi suatu negara. Jika tidak tertangani dengan baik, inflasi dapat menyebabkan alokasi pendanaan yang tidak tepat sasaran dan mengakibatkan meningkatnya angka kemiskinan di suatu negara.

Para pemangku kebijakan ekonomi termasuk pemerintah memiliki ketakutan terhadap inflasi karena dapat menyebabkan pertumbuhan ekonomi negara menjadi menurun [2]. Penurunan pertumbuhan ekonomi menjadi salah satu indikator buruknya kesejahteraan penduduk yang menimbulkan ketidakstabilan keadaan suatu negara. Pada tahun 1998, di Indonesia pernah terjadi inflasi yang cukup besar yaitu dengan laju mencapai 77,63%. Harga barang dan layanan pada saat itu terus mengalami kenaikan disebabkan oleh penurunan nilai tukar rupiah dan ketidakamanan kondisi sosial politik. Besarnya laju inflasi menimbulkan banyak kekacauan dalam berbagai bidang di Indonesia.

Pemahaman terhadap perubahan inflasi merupakan hal yang penting bagi pemegang kebijakan moneter untuk mempertahankan stabilitas harga. Kebijakan moneter yang tepat dapat menurunkan tingkat inflasi yang terjadi di suatu negara walaupun tidak dapat menghilangkannya [3]. Di berbagai negara kebijakan moneter selalu dibuat untuk meminimalisir inflasi yang terjadi. Hal ini mengakibatkan bank sentral yang memegang peranan penting pada aspek moneter selalu membuat target level inflasi yang menjadi tolak ukur efektifnya kebijakan yang diambil [4].

Tingkat perubahan inflasi dari waktu ke waktu dapat menjadi salah satu bahan pertimbangan pemangku kebijakan dalam mengimplementasikan kebijakan yang sesuai. Data *time series* inflasi merupakan modal penting yang dapat dipakai untuk memprediksi laju inflasi yang akan datang, sehingga kebijakan moneter bisa lebih tepat sasaran. Sampai saat ini telah banyak peneliti yang melakukan penelitian tentang prediksi inflasi. Videla [5] melakukan prediksi inflasi menggunakan pendekatan Hamilton Jacobi. Wang [6] melakukan penelitian untuk mengoptimalkan prediksi inflasi menggunakan teori kuantitas. Tule [7] melakukan perbandingan prediksi inflasi harga minyak menggunakan ARIMA dan ARFIMA. Gaglianone [8] melakukan prediksi inflasi di Brasil menggunakan pendekatan kombinasi peramalan univariat. Metode-metode yang telah digunakan ini menggunakan aturan baku yang sering kali tidak dapat memperkirakan pola yang tidak lazim. Hal ini berbeda dengan *metode soft computing* seperti *Fuzzy Neural Network* yang melakukan komputasi dengan meniru kemampuan akal manusia yang luar biasa untuk menalar dan belajar pada lingkungan yang penuh dengan ketidakpastian [9].

Artificial neural network telah mulai digunakan untuk melakukan peramalan dalam bidang ekonomi. Metode peramalan ini banyak digunakan karena mampu memberikan peramalan dengan model *nonlinear*. Keadaan data yang *nonlinear* sering terjadi karena kondisi perekonomian dipengaruhi oleh berbagai faktor sehingga sering terjadi perubahan data yang signifikan. Metode-metode peramalan *non soft computing* seperti pada penelitian-penelitian sebelumnya akan menimbulkan *error* yang cukup besar apabila *data set* yang digunakan mengandung fluktuasi yang besar [10]. Oleh karena itu, penelitian-penelitian tentang peramalan telah banyak dikembangkan menggunakan *soft computing* seperti *fuzzy neural network*. Szafranek [11] mengembangkan model untuk menginvestigasi kualitas dari *one of sample short term* prediksi inflasi yang dikembangkan dengan *neural network*. Thakur [12] melakukan penelitian tentang prediksi inflasi di India berdasarkan *artificial neural network*. Sari [13] melakukan prediksi inflasi di Indonesia berdasarkan indeks harga konsumen menggunakan *neural network*. Penelitian-penelitian ini menggunakan data set berupa data inflasi yang fluktuatif. Hasil peramalan pada masing-masing metode memberikan hasil yang cukup baik sehingga akan diadaptasi pada penelitian ini karena menggunakan tipe *data set* yang sejenis.

Pada penelitian ini, data *time series* diolah menggunakan *neural fuzzy network* untuk memperoleh *training network* yang optimal dan digunakan untuk memprediksi inflasi. *Neural Network* mempunyai kemampuan untuk menganalisa suatu pola data dengan baik, tetapi kurang optimal dalam pengambilan keputusan. Kekurangan ini dapat disempurnakan dengan penambahan konsep logika *fuzzy* yang mampu memperoleh keputusan dari data yang diproses secara lebih tepat. Hal ini mendorong peneliti untuk berusaha memadukan konsep himpunan *fuzzy* dengan *neural network*. *Time series* data yang dimanfaatkan adalah data suku bunga Bank Indonesia, nilai tukar mata uang rupiah terhadap dolar, harga minyak, harga emas, dan jumlah uang yang beredar. Pemilihan variabel ini didasarkan pada penelitian

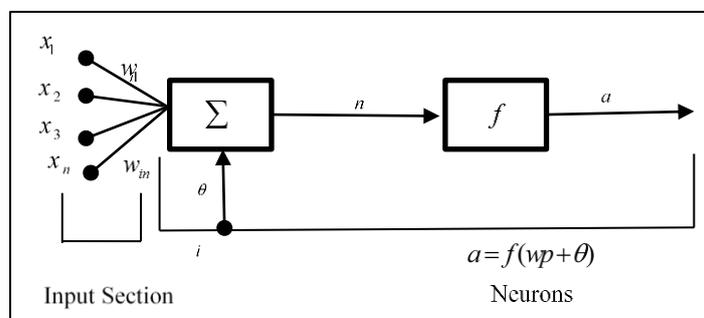
Yolanda [14] yang menyatakan bahwa inflasi di Indonesia dapat dipengaruhi oleh suku bunga Bank Indonesia, nilai tukar mata uang rupiah terhadap dolar, harga minyak, harga emas, dan jumlah uang yang beredar. Menggunakan variabel-variabel ini inflasi akan diprediksi menggunakan *Fuzzy Neural Network*. Pada peramalan ini akan dihasilkan bobot yang menentukan hasil peramalan. Bobot akhir peramalan menggunakan *Fuzzy Neural Network* selanjutnya akan dioptimasi kembali menggunakan algoritma genetika untuk mendapatkan *error* yang lebih kecil. Algoritma genetika dapat diimplementasikan secara mudah dan mempunyai kemampuan menemukan solusi secara tepat pada masalah-masalah yang memiliki dimensi tinggi [15]. Selain itu, teknik optimasi ini memiliki kecocokan dengan *neural network* sehingga akan mampu memberikan hasil yang optimal [16]. Oleh karena itu, penelitian ini akan memprediksi tingkat inflasi di Indonesia menggunakan *Fuzzy Neural Network* yang dioptimasi menggunakan Algoritma genetika.

II. METODE PENELITIAN

A. Artificial neural network

Artificial neural network merupakan sistem *nonlinear* untuk memproses informasi adaptif yang tersusun atas banyak unit pemroses yang terkoneksi [17]. Pada penelitian ini tipe *Artificial Neural Network* yang diterapkan adalah *Backpropagation Neural Network* yang akan dibahas pada bagian selanjutnya. Proses data oleh *artificial neural network* mengadaptasi pada cara kerja otak manusia. Banyak *artificial neuron* sederhana yang terkoneksi secara kompleks dan membentuk *artificial neural network*. *Artificial neural network* sering digunakan dalam prediksi karena memiliki berbagai kelebihan dalam memproses data. *Neural network* ini memiliki kemampuan belajar sendiri yang sangat cocok untuk digunakan dalam memprediksi data. Selain itu, *neural network* juga memiliki kemampuan untuk mencapai titik optimal secara cepat. Solusi terbaik pada permasalahan yang rumit dapat didapatkan dalam waktu yang relatif cepat menggunakan *artificial neural network*. Sistem ini memproses informasi dengan mengadaptasi proses mengingat informasi pada otak. *Artificial neural network* memiliki empat karakteristik [18] diantaranya adalah *non-linear*, *non-limited*, *non-qualitative*, dan *non-convexity*.

Karakter *non-linear* merujuk pada sifat alami dari alam semesta. Kemampuan *neural network* dalam menyikapi perbedaan pada dua tingkatan dalam matematika direpresentasikan sebagai hubungan *non-linear*. Kecerdasan otak yang menjadi rujukan dari *artificial intelligence* merupakan suatu fenomena *non-linear*. Suatu *neural network* mampu meningkatkan kualitas dan meningkatkan toleransi serta kapasitas penyimpanan. *Neural network* dikembangkan dari banyak *neuron* yang saling terkoneksi. Pada otak manusia, sistem memori terdiri atas banyak koneksi antar sel. Karakteristik suatu sistem *neural network* dipengaruhi oleh banyak karakter *neuron* yang saling terkoneksi. Proses interaktif *artificial neural network* sering digunakan untuk mendeskripsikan evolusi dalam sistem dinamis. *Neural network* dapat memproses informasi yang terus berubah dan juga mampu beradaptasi dengan informasi yang berubah secara *non-linear*. Sistem ini memiliki kemampuan untuk mengadaptasi, mengorganisasi, dan mempelajari informasi yang disajikan. *Non-convexity* artinya bahwa sistem ini memiliki banyak *extrema*, sehingga sistem menjadi lebih stabil dalam menghadapi beraneka ragam *evolusi*. Proses ini tidak seperti evolusi sistem biasanya yang tergantung pada satu sistem.



Gambar 1. Model Artifisial Neuron [17]

Gambar 1 menunjukkan bahwa dalam *artificial neural network* terdapat multi input *neuron* ($x_1, x_2, x_3, \dots, x_n$) yang dilambangkan dengan huruf X dan w_{i1}, \dots, w_{in} adalah n komponen bobot *network* koneksi dari i neuron yang dilambangkan dengan huruf w_i . Komponen input x_n masing-masing

terkoneksi dengan bobot w_{in} . Saat stimulus mencapai suatu nilai tertentu, *neuron* akan memberikan implus yang dilambangkan dengan θ_i . Lambang \sum merupakan bagian dari *neuron* yang digunakan untuk menjumlahkan bobot. Terdapat dua macam rumus yang sering digunakan untuk menjumlahkan bobot yaitu Persamaan 1 dan 2.

$$net_i = \sum_{j=1}^n \omega_{ij}x_j + \theta_i \quad (1)$$

$$net_i = \sqrt{\sum_{j=1}^n (x_j - w_{ij})^2} - X - W \quad (2)$$

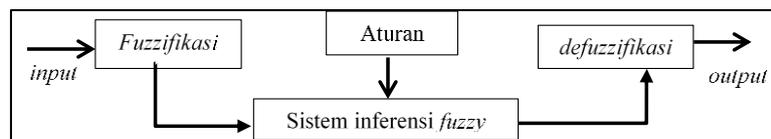
Persamaan 1 merupakan fungsi linear, sedangkan rumus 2 merupakan fungsi *distance*. Pada berbagai kasus fungsi linear lebih sering digunakan untuk menjumlahkan bobot. Fungsi *distance* biasanya digunakan pada fungsi *neural network* berbasis radial. Selanjutnya jumlah bobot akan diubah ke dalam bentuk fungsi aktivasi $f()$ yang terbatas pada suatu selang tertentu. *Output* dari *neural network* ditentukan dengan Persamaan 3. Persamaan 3 merupakan *output* dari i *neuron* dan net_i adalah hasil dari jumlah bobot i *neuron*.

$$y_i = f(net_i) \quad (3)$$

B. Himpunan Fuzzy

Nerural Network memang memiliki kemampuan yang baik dalam pengenalan pola namun tidak baik dalam menjelaskan proses mencapai keputusan, *fuzzy* dapat mengatasi kelemahan ini karena mampu menjelaskan keputusan dari data-data dengan informasi yang tidak tepat [19]. Himpunan *fuzzy* merupakan pengembangan dari himpunan klasik yang sering digunakan [20]. Sistem keanggotaan himpunan *fuzzy* berbeda dengan himpunan klasik pada umumnya. Pada himpunan klasik keanggotaan dilambangkan dengan 1 dan 0 saja. Keanggotaan 1 menyatakan bahwa suatu komponen adalah anggota dari himpunan, sedangkan keanggotaan 0 menyatakan bukan anggota. Pada himpunan *fuzzy* keanggotaan dilambangkan dengan bilangan real pada selang [0,1]. Dengan demikian, setiap unit akan tetap merupakan anggota himpunan jika memiliki nilai keanggotaan dalam rentang 0 sampai 1.

Penerapan himpunan *fuzzy* dalam suatu prediksi terkait erat dengan sistem *fuzzy*. Sistem *fuzzy* tersusun atas tiga tahapan utama yaitu, fuzzifikasi, sistem inferensi *fuzzy*, dan defuzzifikasi. Sistem *fuzzy* diilustrasikan melalui Gambar 2.

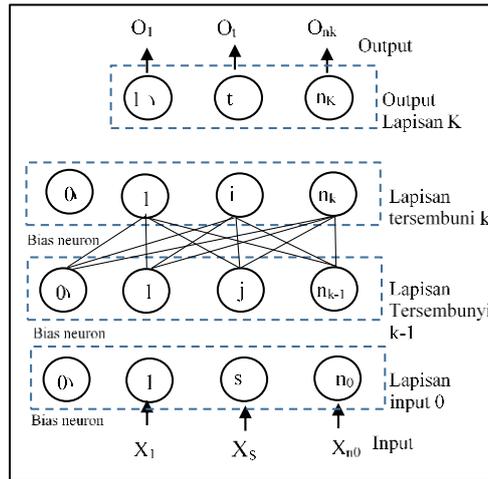


Gambar 2. Sistem Fuzzy

Tahap fuzzifikasi dilakukan untuk mengkonversi bilangan *crisp* ke dalam derajat keanggotaan *fuzzy* dengan suatu fungsi keanggotaan. Sistem inferensi *fuzzy* adalah proses penalaran untuk memperoleh output. Defuzzifikasi dapat dikatakan sebagai proses kebalikan dari fuzzifikasi yaitu mengkonversi himpunan *fuzzy* ke bentuk himpunan klasik.

C. Back Propagation Neural Network

Backpropagation neural network adalah algoritma *training* yang digunakan untuk mengolah bobot dalam rangka meminimalisir kesalahan dalam *output neural network* [21]. BPNN dapat memproses banyak input *output* tanpa harus mengetahui secara tepat formula matematika yang dibutuhkan. BPNN mampu untuk terus memproses data dan memperbaiki *error* sampai parameter beradaptasi terhadap semua *input* [22]. Susunan *fuzzy neural network* dengan $K+1$ layer ditampilkan seperti pada Gambar 3.



Gambar 3. Arsitektur Fuzzy Neural Network

Backpropagation memperbaiki nilai *error* agar hasil perhitungan lebih optimal. Proses *Backpropagation* akan terus dilakukan terus menerus sampai tercapai *error* yang diinginkan. Prosedur *Backpropagation* meliputi beberapa langkah.

Pertama, menentukan faktor δ unit keluaran atas dasar kesalahan unit ($Y_k, k=1$) menggunakan Persamaan 4.

$$\delta_k = (T_k - Y_k) \cdot f' \cdot (Y_{net_k}) \quad (4)$$

Pada Persamaan 4, δ_k merupakan faktor kesalahan dalam merubah bobot *layer* selanjutnya. selanjutnya menentukan koreksi bobot (Δw_{jk}) yang akan dipakai untuk mengoreksi bobot *layer* tersembunyi (w_{jk}) dengan laju pembelajaran α menggunakan Persamaan 5.

$$\Delta w_{jk} = \alpha \cdot \delta_k \cdot z_j \quad (5)$$

Kemudian, koreksi bias (Δw_{ok}) juga ditentukan untuk memperbaiki nilai w_{ok} menggunakan Persamaan 6.

$$\Delta w_{ok} = \alpha \cdot \delta_k \quad (6)$$

Kedua, menemukan faktor δ pada unit tersembunyi berdasarkan kesalahan tiap unit ($z_j, j=1,2,\dots,p$) menggunakan Persamaan 7.

$$\delta_{net_j} = \sum_{k=1}^m \delta_k \cdot w_{jk} \quad (7)$$

Faktor δ unit tersembunyi ditentukan dengan Persamaan 8.

$$\delta_j = \delta_{net_j} f'(Z_{net_j}) \quad (8)$$

Selanjutnya koreksi bobot input (Δv_{ij}) untuk memperbaiki nilai v_{ij} ditentukan dengan Persamaan 9.

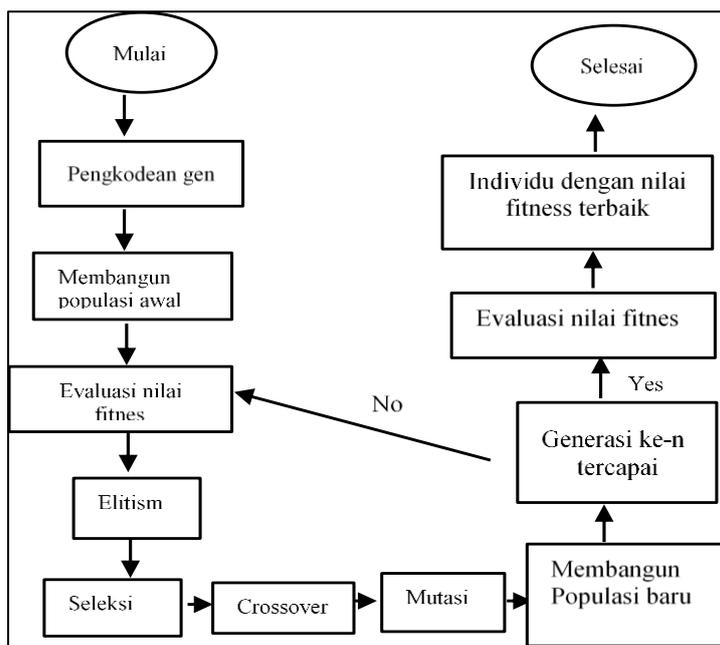
$$\Delta v_{ij} = \alpha \cdot \delta_i \cdot x_i \quad (9)$$

Koreksi bias input (Δv_{oj}) dihitung untuk menggantikan nilai bias input v_{oj} dengan Persamaan 10

$$\Delta v_{oj} = \alpha \cdot \delta_j \tag{10}$$

D. Algoritma Genetika

Algoritma genetika merujuk pada teknik yang dilakukan berdasarkan mekanisme genetik alami dan seleksi alami [23]. Pada suatu seleksi, individu terkuat akan bertahan dan individu lain akan hilang. Pola pikir utama dalam algoritma genetika adalah berusaha memperoleh individu terbaik sebagai solusi optimal suatu permasalahan. Algoritma ini akan melakukan dua proses utama yaitu mutasi dan seleksi. Setiap generasi akan melalui proses mutasi dan seleksi. Proses ini akan menghasilkan solusi optimal setelah beberapa generasi. Proses yang dilalui pada algoritma genetika direpresentasikan pada Gambar 4.



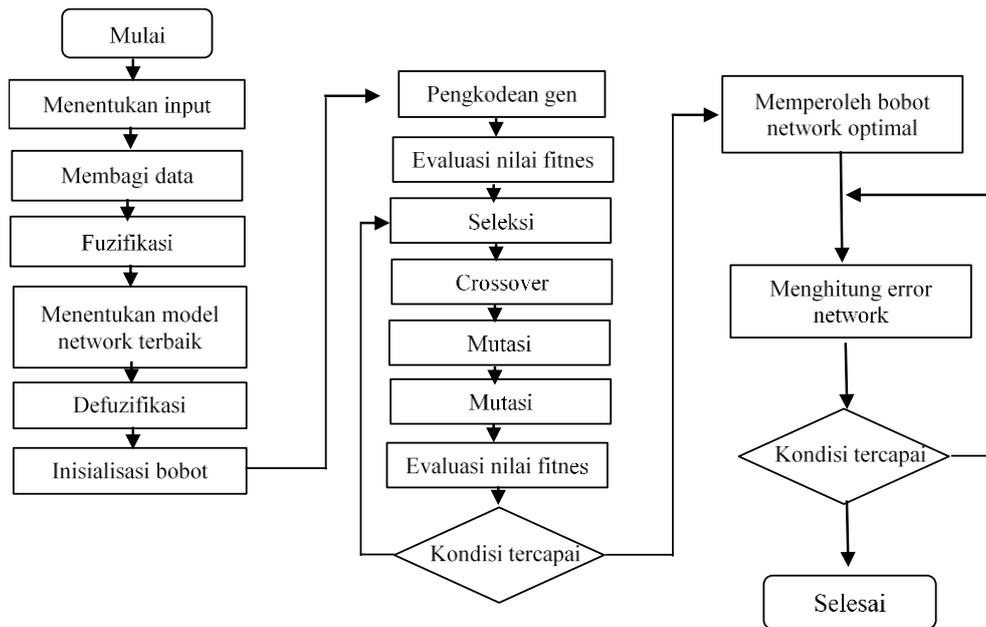
Gambar 4. Bagan Algoritma Genetika

E. Fuzzy Back Propagation Neural Network Dioptimasi dengan Algoritma Genetika

Prediksi menggunakan *fuzzy backpropagation Neural network* dioptimasi menggunakan algoritma genetika merupakan perpaduan antara tiga komponen yang berpotensi untuk menghasilkan prediksi optimal. Logika *fuzzy* membuat prediksi yang dilakukan menjadi lebih optimal karena tidak lagi terkurung dalam logika *crisp* yang kaku. Dalam prediksi ini, individu (kumpulan beberapa gen) yang terbentuk akan diproses dan dievaluasi pada waktu yang bersamaan untuk memperoleh solusi terbaik. Pada saat optimasi, Algoritma genetika akan menggunakan nilai *fitness* fungsi objektif sebagai acuan utama dan memperbaikinya solusi secara lebih efektif. *Flowchart* proses prediksi menggunakan *fuzzy backpropagation Neural Network* yang dioptimasi menggunakan Algoritma Genetika disajikan pada Gambar 5.

Hasil peramalan yang telah diperoleh dievaluasi menggunakan *Mean Absolute Percentage Error* (MAPE). MAPE merupakan teknik perhitungan *error* yang paling sering digunakan dalam peramalan di bidang ekonomi karena dianggap paling sesuai dengan tipe data yang diolah [24]. Nilai MAPE merupakan presentase nilai rerata *Absolute Error* dari kesalahan prediksi. Nilai ini menunjukkan selisih antara data peramalan dan data asli. Dengan demikian, semakin kecil nilai MAPE maka hasil peramalan akan semakin akurat.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \bar{Y}_t|}{Y_t} \times 100\% \tag{11}$$



Gambar. 5. Flowchat Fuzzy Backpropagation Neural Network dioptimasi dengan Algoritma Genetika

Pada Persamaan 11, Y_t menunjukkan nilai pengamatan ke- t dan \bar{Y}_t menunjukkan nilai peramalan pada waktu ke- t . Setelah mengetahui tingkat *error* yang dihasilkan oleh masing-masing peramalan, akan diperbandingkan antara metode peramalan *Fuzzy Artificial Neural Network* dan *Fuzzy Artificial Neural Network* yang telah dioptimasi menggunakan algoritma genetika menggunakan statistik uji *independent sample t test*. Rumus independent sample t test dapat dilihat pada Persamaan 12.

$$t = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} \quad (12)$$

Dengan \bar{X}_1 merupakan rerata *error* pada prediksi menggunakan *Fuzzy Artificial Neural Network* yang telah dioptimasi menggunakan algoritma genetika. \bar{X}_2 rerata *error* pada prediksi menggunakan *Fuzzy Artificial Neural Network*. s melambangkan nilai varians, dan melambangkan banyak data pada masing-masing prediksi. Pada penelitian ini, perhitungan *independent sample t test* akan menggunakan bantuan SPSS.

III. HASIL DAN PEMBAHASAN

Proses prediksi inflasi menggunakan *fuzzy backpropagation neural network* yang dioptimasi menggunakan algoritma genetika dilakukan dengan bantuan MATLAB. Faktor penyebab perubahan inflasi yang diamati pada penelitian ini meliputi suku bunga Bank Indonesia, nilai tukar mata uang rupiah terhadap dolar, harga minyak, harga emas, dan jumlah uang yang beredar. Data diperoleh melalui laman resmi bank indonesia (www.bi.go.id) dan laman resmi badan pusat statistik Indonesia (www.bps.go.id). Data yang dikumpulkan berupa data berkala tiap bulan pada rentang Januari 2009-Mei 2020 sebanyak 135 data. Menggunakan teknik *10 fold crossvalidation* data dibagi dengan perbandingan 8 : 2.

A. Fuzzy Backpropagation Neural Network

Terdapat beberapa tahap yang dilalui dalam pengembangan sistem *fuzzy backpropagation neural network* untuk memprediksi inflasi di Indonesia. Tahap pertama yang dilakukan adalah mendefinisikan input yang akan digunakan. Teknik penentuan input yang dipakai pada penelitian ini adalah berdasarkan grafik *Partial Autocorelation Function* (PACF). Pembentukan grafik PACF dilakukan menggunakan

bantuan program MINITAB. Pada grafik yang di hasilkan masing-masing variabel akan menunjukkan beberapa *lag*. *Lag* signifikan pada masing-masing variabel ditunjukkan pada Tabel 1.

TABEL 1
LAG SIGNIFIKAN SETIAP VARIABEL

Variabel	Lag Signifikan	Total
Inflasi	Lag 1, lag 27	2
Suku bunga	Lag 1, lag 6	2
Nilai Tukar Rupiah	Lag 1, lag 8, lag 13, lag 22	4
Harga minyak	Lag 1, lag 3, lag 4	3
Harga emas	Lag 1	1
Uang beredar	Lag 1	1

Hasil PACF menunjukkan bahwa nilai lag tertinggi adalah lag 27. Dengan demikian, target variabel inflasi dimulai pada data ke-28 hingga data ke-135. Berdasarkan proses yang dilakukan menggunakan PACF digunakan 108 data untuk input dengan 13 variabel. Data kemudian dikelompokkan menjadi dua komponen yaitu data latih dan data uji. Pembagian data didasarkan pada proporsi yang dilakukan pada penelitian Hota [25]. Komposisi pembagian data menggunakan teknik *10 fold crossvalidation* dengan perbandingan 8 : 2. Artinya 87 data akan digunakan sebagai data latih dan 22 data digunakan sebagai data uji.

Variabel input yang dibutuhkan pada sistem adalah berupa bilangan *fuzzy*. Oleh karena itu, dilakukan proses fuzifikasi pada data yang diperoleh. Fuzifikasi dilakukan dengan fungsi keanggotaan *S* pertumbuhan. Tipe fungsi keanggotaan ini dipilih karena sesuai dengan tipe data *nonlinear* yang digunakan dalam penelitian ini [26].

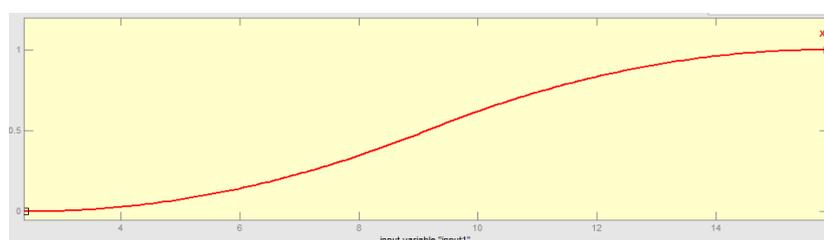
Sebagai contoh pada salah satu domain input yaitu [5.462 17.820] dengan fungsi keanggotaan kurva *S* pertumbuhan diperoleh persamaan fungsi keanggotaan himpunan *fuzzy* A_1 sebagai Persamaan 13.

$$\mu_{A_1}(x) = \begin{cases} 0 & x \leq 5.462 \\ 2 \left(\frac{x - 5.462}{17.820 - 5.462} \right)^2 & 5.462 \leq x \leq 11.641 \\ 1 - 2 \left(\frac{17.820 - x}{17.820 - 5.462} \right)^2 & 11.641 \leq x \leq 17.820 \\ 1 & x \geq 17.820 \end{cases} \quad (13)$$

Misal nilai variabel X_1 pada data pengamatan ke-1 data *input training* sebesar 9.211 selanjutnya nilai tersebut disubstitusikan ke Persamaan 13. Nilai 9.211 berada pada $5.462 \leq x \leq 11.641$ maka menjadi:

$$\mu_{A_1}(9.211) = 2 \left(\frac{9.211 - 5.462}{17.820 - 5.462} \right)^2 = 0,1841$$

Sehingga diperoleh derajat keanggotaan 9.211 pada himpunan *Fuzzy* A_1 sebesar 0,1841. Kurva fungsi keanggotaan *S* disajikan pada Gambar 6.



Gambar 6. Grafik Fuzzifikasi Fungsi Keanggotaan *S*

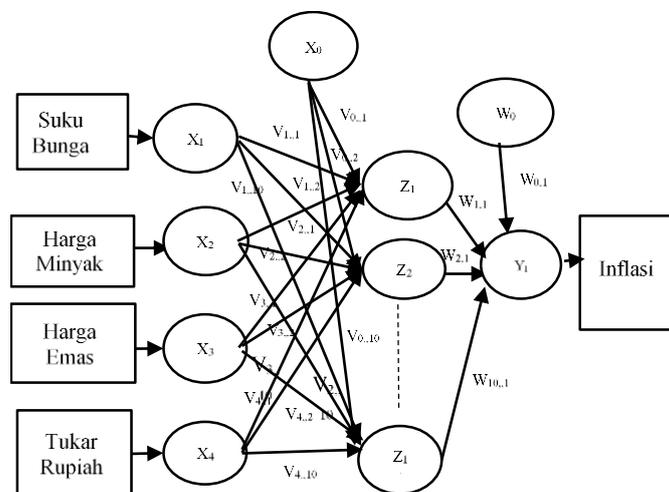
Data yang telah melalui proses fuzifikasi digunakan untuk menyusun model jaringan terbaik FBPNN. Komponen utama yang berperan dalam proses ini merupakan derajat keanggotaan himpunan *fuzzy*. Pada penelitian ini digunakan arsitektur model dengan banyak *layer*. *Sigmoid biner* dipilih untuk menjadi fungsi aktivasi pada *layer* tersembunyi dan *output*. Fungsi *sigmoid* dipilih agar *output* yang dihasilkan tidak keluar dari interval [0,1]. *Sigmoid biner* merupakan fungsi keanggotaan yang digunakan pada

jaringan syarat tiruan dengan algoritma pembelajaran *backpropagation* [27]. Penelitian sebelumnya [28] juga menunjukkan bahwa jika dibandingkan dengan fungsi aktivasi lainnya *sigmoid biner* memiliki efektivitas yang baik. Berdasarkan penelitian sebelumnya diketahui juga bahwa fungsi aktivasi sigmoid biner memiliki keunggulan dibandingkan dengan fungsi aktivasi lainnya. Fungsi ini dapat dihitung secara manual menggunakan Persamaan 14.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (14)$$

dimana $f'(x) = f(x)[1 - f(x)]$.

Sementara itu, metode pembelajaran yang dipakai adalah metode pembelajaran terawasi dan algoritma *backpropagation*. Dalam metode terawasi pola yang diberikan sudah diketahui *output-nya*. *Error* yang merupakan selisih antara *output* sesungguhnya dengan *output* yang diinginkan dipakai untuk melakukan koreksi terhadap bobot jaringan yang dihasilkan. Hal ini dilakukan agar dapat diperoleh bobot yang optimal. Menggunakan bantuan MATLAB tahap-tahap ini dilakukan dengan perintah `net=newff(minmax(PF1),[n 1],{'logsig' 'logsig'},'traingdx')`; Pada perintah ini terdapat beberapa komponen yang memiliki fungsi berbeda. Perintah `newff` dilakukan untuk memanggil jaringan *backpropagation* yang akan digunakan. Melalui perintah ini akan didapatkan sebanyak n neuron pada *hidden layer* dan 1 neuron pada *output layer*. Fungsi aktivasi *sigmoid* dipanggil dengan perintah `{'logsig' 'logsig'}`. Selanjutnya perintah `traingdx` digunakan untuk memanggil fungsi pembelajaran yang digunakan. Penentuan banyak neuron pada *hidden layer* dilakukan dengan mengacu pada nilai MAPE terkecil. Berdasarkan proses yang dilakukan, pada penelitian ini diketahui bahwa *hidden layer* terbaik berjumlah sepuluh, dengan empat input yaitu suku bunga lag ke-1, harga minyak lag ke-3, harga emas lag ke-1, dan Nilai tukar rupiah lag ke-8. Dalam suatu FBPNN bisa jadi terdapat banyak *hidden layer* [29]. Gambar 7 menunjukkan model FBPPN yang terbentuk dengan 4 *input*, 10 *hidden layer*, dan 1 *output*.



Gambar 7. Desain FBPPN

Secara matematis model FBPPN pada Gambar 7 dapat disajikan dalam Persamaan 15.

$$y = \frac{1}{1 + e^{-(w_{0k} + \sum_{j=1}^{10} \frac{1}{1 + e^{-(v_{0j} + \sum_{i=1}^{10} x_i v_{ij})} w_{jk})}} \quad (15)$$

B. Optimasi menggunakan Algoritma Genetika

Optimasi menggunakan algoritma genetika dipercaya memiliki prospek yang baik untuk memperbaiki hasil peramalan menggunakan *Fuzzy Backpropagation Neural Network* (FBPNN) [18]. Pada tahap FBPNN telah diperoleh bobot-bobot akhir sistem prediksi inflasi. Selanjutnya, menggunakan Algoritma Genetika, bobot tersebut akan diolah kembali sehingga dihasilkan bobot yang lebih optimal dengan

error sekecil mungkin. *Error* pada optimasi ini merupakan presentase nilai rata-rata *absolute error* atau MAPE. Tahap optimasi menggunakan Algoritma Genetika melalui beberapa tahap yang dimulai dengan pengkodean gen.

Teknik pengkodean yang digunakan pada penelitian ini adalah pengkodean nilai riil. Pengkodean ini menggunakan nilai asli dari bobot akhir FBPNN menjadi gen. Banyak gen yang dihasilkan sesuai dengan jumlah bobot akhir FBPNN yaitu sebanyak 63. Setelah gen didefinisikan langkah selanjutnya adalah membangkitkan populasi awal. Populasi disusun berdasarkan kumpulan individu, dimana satu individu terbentuk atas beberapa gen. Teknik yang digunakan untuk membangkitkan populasi awal adalah *random generator* dengan pendekatan nilai tertentu. Pada individu pertama diisi dengan bobot akhir dalam proses FBPNN, kemudian untuk individu ke-2 dan seterusnya akan disusun dari nilai-nilai acak. Proses evaluasi nilai bobot sudah mulai dilakukan pada tahap ini. Langkah yang digunakan adalah evaluasi nilai *fitness*. Bobot diolah agar memiliki *error* sekecil mungkin. Proses ini akan ditentukan oleh nilai MAPE yang dihasilkan. Masing-masing individu ditentukan nilai fitnessnya dengan bantuan MATLAB.

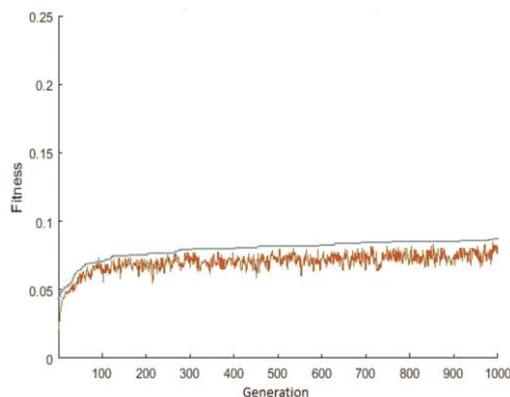
Hasil nilai *fitness* digunakan pada tahap selanjutnya yaitu *Elitism*. Proses yang dilakukan pada tahap ini adalah menyimpan dan mempertahankan individu dengan nilai *fitness* terbaik. Hal ini dilakukan karena pada tahap seleksi nantinya akan dilakukan secara acak sehingga besar kemungkinan individu dengan nilai *fitness* terbaik malah tidak terpilih. Setelah terpilih, individu dengan nilai *fitness* terbaik akan dipertahankan kembali sebagai generasi ke-2 dengan tujuan untuk menjaganya agar tidak rusak pada tahap *crossover* dan mutasi.

Sebelum memasuki tahap *crossover* dan mutasi dilakukan tahap seleksi. Tahap *crossover* dan mutasi merupakan tahap terpenting dalam algoritma genetika sehingga tahapan sebelumnya harus disiapkan dengan baik [30]. Pada penelitian ini metode seleksi yang digunakan adalah *rank based selection*. Metode seleksi ini dipilih untuk menghindari terjadinya lokal optimal karena akan dihasilkan keragaman relatif lebih banyak. Tahapan yang dilakukan dimulai dengan menghitung nilai *fitness* masing-masing individu yang termuat pada populasi awal. Nilai yang sudah diperoleh kemudian diurutkan dimulai dari yang terkecil. Hasil pengurutan ini diberi nilai *fitness* baru mulai sebesar satu untuk individu pertama, dua untuk individu ke-2 dan begitu seterusnya. Langkah selanjutnya keseluruhan nilai *fitness* dijumlahkan pada setiap individu. Pada masing-masing individu juga dihitung nilai probabilitasnya dengan membagi setiap nilai *fitness*. Nilai probabilitas kumulatif didapatkan pada akhir proses ini. Selanjutnya dibangkitkan dua nilai *random* pada interval [0 1]. Menggunakan MATLAB nilai *random* yang didapatkan adalah 0.1187 dan 0.5671. Individu dengan nilai frekuensi kumulatif ini dipilih sebagai induk untuk proses *crossover*.

Tahap selanjutnya dari proses optimasi FBPNN adalah *crossover*. *Crossover* diterapkan untuk induk yang telah terseleksi. Tahap ini bertujuan menghasilkan individu baru. Probabilitas *Crossover* yang digunakan adalah sebesar 0,8. Menggunakan MATLAB dibangkitkan probabilitas induk dan diperoleh angka sebesar 0,0965 sehingga *crossover* dapat dilakukan. Posisi gen yang *crossover* ditentukan dengan membangkitkan dua nilai acak menggunakan bantuan matlab. Gen yang dipindah silangkan adalah gen ke-35 sampai gen ke-37.

Pada sepasang anak yang diperoleh melalui *crossover* selanjutnya akan dimutasi. Mutasi dilakukan guna memperoleh individu baru sebagai kandidat terbaik. Teknik mutasi yang digunakan pada penelitian ini adalah *random mutation*. Teknik ini mengganti nilai gen yang sudah ada menggunakan bilangan *random*. Nilai probabilitas mutasi yang digunakan adalah sebesar 0,02. Nilai probabilitas mutasi pada individu sebesar 0,023 pada anak 1 dan 0,005 pada anak 2. Penentuan gen yang akan dimutasi dilakukan dengan membangkitkan nilai acak pada interval [1 63]. Langkah terakhir yang dilakukan adalah membentuk populasi pada generasi selanjutnya. Anak-anak yang pada proses sebelumnya didapatkan digunakan untuk mengganti posisi induk di populasi baru. Proses evaluasi nilai *fitness* hingga mutasi diulang kembali pada tahap ini, sehingga diperoleh bobot yang paling optimal.

Setelah melalui serangkaian percobaan diperoleh ukuran populasi yang dapat diterima yaitu sebanyak 45 dengan 1000 generasi dan nilai *fitness* sebesar 0.4230. Grafik optimasi FBPNN menggunakan algoritma genetika disajikan pada Gambar 8.



Gambar 8. Grafik Optimasi FBPNN menggunakan Algoritma Genetika

C. Prediksi Inflasi di Indonesia

Sistem FBPNN yang telah dioptimasi menggunakan algoritma genetika kemudian digunakan untuk memprediksi inflasi yang terjadi di Indonesia. Peramalan inflasi dilakukan pada periode Maret 2020 hingga Mei 2020. Variabel input yang digunakan adalah suku bunga, harga minyak, harga emas, dan jumlah uang beredar seperti yang disajikan pada Tabel 1.

TABEL 1
VARIABEL INPUT PREDIKSI

Bulan Peramalan	Variabel Input			
	Suku bunga	Harga Minyak	Harga Emas	Kurs Dollar
Maret	4.5	20,48	1.592,10	16.310,0
April	4.5	19,56	1.694,20	14.875,0
Mei	4.5	35,49	1.751,70	14.610,0

Pada Tabel 1, suku bunga dinyatakan dalam persen, harga minyak merupakan harga tiap barel yang disajikan dalam satuan ribu dolar, harga emas merupakan harga tiap satu troy ons dengan satuan ribu dolar, sedangkan kurs dollar merupakan nilai tukar tiap satu dollar dalam mata uang rupiah. Nilai variable input selanjutnya diproses melalui langkah fuzifikasi menggunakan fungsi keanggotaan S agar bisa digunakan pada tahap prediksi FBPNN. Pada masing-masing metode selanjutnya ditentukan nilai MAPE-nya untuk menentukan keefektivan metode yang digunakan. Nilai MAPE FBPNN ditentukan dengan Persamaan 11 sebagai berikut.

$$MAPE = \frac{1}{3} \left(\frac{|2.96 - 3.21|}{2.96} + \frac{|2.67 - 2.29|}{2.67} + \frac{|2.19 - 2.42|}{2.19} \right) \times 100\% = 11.06\%$$

Menggunakan cara yang sama, MAPE juga ditentukan pada FBPNN dengan Algoritma Genetika. Hasil peramalan inflasi menggunakan FBPNN dan FBPNN yang telah dioptimasi menggunakan algoritma genetika yang disajikan pada Tabel 2.

TABEL 2
HASIL PREDIKSI INFLASI INDONESIA

Model	Maret 2020	April 2020	Mei 2020	MAPE
Inflasi	2.96	2.67	2.19	
FBPNN	3.21	2.29	2.42	11.06%
FBPNN dengan Algoritma Genetika	3.2	2.74	2.63	10.27%

Tabel 2 menggambarkan terdapat perbedaan nilai MAPE sebesar 0,79% pada hasil prediksi menggunakan FBPNN saja dan FBPNN yang telah dioptimasi menggunakan algoritma genetika. Perbedaan ini menunjukkan bahwa FBPNN yang telah dioptimasi dengan algoritma genetika mampu melakukan prediksi inflasi secara lebih baik. Hasil penelitian ini sejalan dengan hasil yang ditemukan oleh Pooya [31] dalam melakukan prediksi filter benang dan memperkuat penelitian Leila [32] bahwa *artificial neural network* sesuai untuk tipe data dengan log yang jelas. Walaupun demikian, hasil prediksi menggunakan FBPNN saja juga sudah cukup baik sejalan dengan penelitian yang telah dilakukan oleh Borisagar [21].

Keunggulan teknik peramalan FBPNN dengan menggunakan algoritma genetika juga dikonfirmasi berdasarkan uji statistik *independent sample t test* dengan bantuan SPSS dimana diketahui bahwa pada tingkat kepercayaan 95% prediksi menggunakan Fuzzy ANN yang telah dioptimasi menggunakan algoritma genetika ($M= 0,69, SD= 0,0421$) lebih baik secara signifikan dibandingkan dengan fuzzy ANN saja ($M= 0,97, SD= 0,04634$), $t(22) = 1.71714, p=0.013$.

IV. KESIMPULAN

Fuzzy Neural Network memiliki kemampuan yang menjanjikan dalam memprediksi inflasi yang terjadi di Indonesia. Hasil menunjukkan bahwa prediksi menggunakan *fuzzy backpropagation neural network* dioptimasi menggunakan algoritma genetika memberikan prediksi yang lebih baik dibandingkan dengan prediksi menggunakan *fuzzy backpropagation neural network* saja. Perbedaan yang dihasilkan mencapai 0,79%. Hasil ini juga dikonfirmasi menggunakan uji statistika *independent sample t test* dimana diketahui bahwa pada tingkat kepercayaan 95% prediksi menggunakan Fuzzy ANN yang telah dioptimasi menggunakan algoritma genetika ($M= 0,69, SD= 0,0421$) lebih baik secara signifikan dibandingkan dengan fuzzy ANN saja ($M= 0,97, SD= 0,04634$), $t(22) = 1.71714, p=0.013$. Penelitian ini berfokus pada beberapa data input yaitu harga minyak dunia, harga emas, tingkat suku bunga, dan kurs mata uang Indonesia terhadap dolar. Inflasi dipengaruhi oleh banyak faktor yang belum semuanya tercakup dalam penelitian ini. Pada penelitian selanjutnya jika dimensi dan sudut pandang mengenai inflasi diperluas, maka hasil prediksi diharapkan akan menjadi lebih akurat. Dengan demikian perlu dilakukan penelitian lanjutan dengan mempertimbangkan faktor-faktor yang mempengaruhi inflasi serta menggunakan variasi teknik dalam melakukan prediksi terhadap inflasi.

DAFTAR PUSTAKA

- [1] M. Uddin and A. Moniruzzaman, "Inflation, inflation uncertainty and relative price variability in Bangladesh," *Eurasian Econ. Rev.*, no. 6, pp. 389–427, 2016, doi: 10.1007/s40822-016-0055-8.
- [2] K. U. Ehigiamusoe, H. H. Lean, and C. C. Lee, "Moderating effect of inflation on the finance–growth nexus: insights from West African countries," *Empir. Econ.*, vol. 57, no. 2, pp. 399–422, 2019, doi: 10.1007/s00181-018-1442-7.
- [3] J. H. Powell, "Monetary policy and risk management at a time of low inflation and low unemployment," *Bus. Econ.*, vol. 53, no. 4, pp. 173–183, 2018, doi: 10.1057/s11369-018-0099-8.
- [4] L. A. Gil-Alana, A. Mervar, and J. E. Payne, "The stationarity of inflation in Croatia: anti-inflation stabilization program and the change in persistence," *Econ. Chang. Restruct.*, vol. 50, no. 1, pp. 45–58, 2017, doi: 10.1007/s10644-016-9181-2.
- [5] N. Videla, "Hamilton–Jacobi approach for quasi-exponential inflation: predictions and constraints after Planck 2015 results," *Eur. Phys. J. C*, vol. 77, no. 3, 2017, doi: 10.1140/epjc/s10052-017-4711-2.
- [6] Y. Wang, Y. Tu, and S. X. Chen, "Improving inflation prediction with the quantity theory," *Econ. Lett.*, vol. 149, pp. 112–115, 2016, doi: 10.1016/j.econlet.2016.10.023.
- [7] M. Tule, A. Salisu, and C. Chiemekwe, "Improving Nigeria's Inflation Forecast with Oil Price: The Role of Estimators," *J. Quant. Econ.*, 2019, doi: 10.1007/s40953-019-00178-8.
- [8] W. P. Gaglianone, J. V. Issler, and S. M. Matos, "Applying a microfounded-forecasting approach to predict Brazilian inflation," *Empir. Econ.*, vol. 53, no. 1, pp. 137–163, 2017, doi: 10.1007/s00181-016-1163-8.
- [9] J.-S. Jang, C.-T. Sun, and E. Mizutani, *Neuro Fuzzy and Soft Computing*. Prentice Hall, 1997.
- [10] J. Nayak, G. T. Chandrasekhar, B. Naik, D. Pelusi, and A. Abraham, "Special issue on 'Soft computing techniques: applications and challenges' neural computing and applications," *Neural Comput. Appl.*, vol. 32, no. 12, p. 7585, 2020, doi: 10.1007/s00521-020-04902-x.
- [11] K. Szafrank, "Bagged neural networks for forecasting Polish (low) inflation," *Int. J. Forecast.*, vol. 35, no. 3, pp. 1042–1059, 2019, doi: 10.1016/j.ijforecast.2019.04.007.
- [12] G. S. M. Thakur, R. Bhattacharyya, and S. S. Mondal, "Artificial Neural Network Based Model for Forecasting of Inflation in India," *Fuzzy Inf. Eng.*, vol. 8, no. 1, pp. 87–100, 2016, doi: 10.1016/j.fiae.2016.03.005.
- [13] N. R. Sari, W. F. Mahmudy, and A. P. Wibawa, "Backpropagation on neural network method for inflation rate forecasting in Indonesia," *Int. J. Adv. Soft Comput. its Appl.*, vol. 8, no. 3, pp. 69–87, 2016.
- [14] Y. Yolanda, "Analysis of factors affecting inflation and its impact on human development index and poverty in Indonesia," *Eur. Res. Stud. J.*, vol. 20, no. 4, pp. 38–56, 2017, doi: 10.35808/ersj/873.
- [15] Suyanto, *Artificial Intelligence Searching, Reasoning, Planning, dan Learning Revisi Kedua*. Bandung: Informatika Bandung, 2014.
- [16] Z. Chen, A. Huang, and X. Qiang, "Improved Neural Networks Based on Genetic Algorithm for Pulse Recognition," *Comput. Biol. Chem.*, vol. 88, no. May, p. 107315, 2020, doi: 10.1016/j.compbiolchem.2020.107315.
- [17] X. Wang and B. Wang, "Research on prediction of environmental aerosol and PM_{2.5} based on artificial neural network," *Neural Comput. Appl.*, vol. 31, no. 12, pp. 8217–8227, Dec. 2019, doi: 10.1007/s00521-018-3861-y.
- [18] Y. chen Wu and J. wen Feng, "Development and Application of Artificial Neural Network," *Wirel. Pers. Commun.*, vol. 102, no. 2, pp. 1645–1656, 2018, doi: 10.1007/s11277-017-5224-x.
- [19] R. Fuller, *Neural Fuzzy Systems*. Åbo: Åbo Akademi., 1995.
- [20] L.-X. Wang, *A Course in Fuzzy Systems and Control*. Prentice-Hall, 1997.
- [21] N. Borisagar, D. Barad, and P. Ravai, "Chronic Kidney Disease Prediction Using Back Propagation Neural Network Algorithm," in *Proceedings of International Conference on Communication and Networks*, 2017, vol. 508, pp. 295–303, doi: 10.1007/978-981-10-2750-5.
- [22] Y. Liu, Y. Chen, S. Wu, G. Peng, and B. Lv, "Composite leading search index: a preprocessing method of internet search data for stock trends prediction," *Ann. Oper. Res.*, vol. 234, no. 1, pp. 77–94, 2015, doi: 10.1007/s10479-014-1779-z.

- [23] M. Yassami and P. Ashtari, "Using fuzzy genetic, Artificial Bee Colony (ABC) and simple genetic algorithm for the stiffness optimization of steel frames with semi-rigid connections," *KSCE J. Civ. Eng.*, vol. 19, no. 5, pp. 1366–1374, 2015, doi: 10.1007/s12205-014-0517-z.
- [24] J. McKenzie, "Mean absolute percentage error and bias in economic forecasting," *Econ. Lett.*, vol. 113, no. 3, pp. 259–262, 2011, doi: 10.1016/j.econlet.2011.08.010.
- [25] & S. Hota, Shrivastava, "Artificial Neural Network, Decision Tree and Statistical Techniques Applied for Designing and Developing E-mail Classifier," *Int. J. Recent Technol. Eng.*, no. 6, pp. 164–169, 2013.
- [26] J. M. Adánez, B. M. Al-Hadithi, and A. Jiménez, "Multidimensional membership functions in T–S fuzzy models for modelling and identification of nonlinear multivariable systems using genetic algorithms," *Appl. Soft Comput. J.*, vol. 75, pp. 607–615, 2019, doi: 10.1016/j.asoc.2018.11.034.
- [27] S. Kusumadewi and H. Purnomo, *Aplikasi Logika Fuzzy untuk Pendukung Keputusan*. Yogyakarta: Graha Ilmu, 2010.
- [28] M. A. Mansor and S. Sathasivam, "Activation function comparison in neural-symbolic integration," *AIP Conf. Proc.*, vol. 1750, no. June 2016, 2016, doi: 10.1063/1.4954526.
- [29] Y. Liu, L. Xu, and M. Li, "The Parallelization of Back Propagation Neural Network in MapReduce and Spark," *Int. J. Parallel Program.*, vol. 45, no. 4, pp. 760–779, 2017, doi: 10.1007/s10766-016-0401-1.
- [30] S. Muniyappan and P. Rajendran, "Contrast Enhancement of Medical Images through Adaptive Genetic Algorithm (AGA) over Genetic Algorithm (GA) and Particle Swarm Optimization (PSO)," *Multimed. Tools Appl.*, vol. 78, no. 6, pp. 6487–6511, 2019, doi: 10.1007/s11042-018-6355-0.
- [31] P. Abdolghader, F. Haghghat, and A. Bahloul, "Predicting Fibrous Filter's Efficiency by Two Methods: Artificial Neural Network (ANN) and Integration of Genetic Algorithm and Artificial Neural Network (GAINN)," *Aerosol Sci. Eng.*, vol. 2, no. 4, pp. 197–205, 2018, doi: 10.1007/s41810-018-0036-2.
- [32] R. A. Abdula, *Advances in Petroleum Engineering and Petroleum Geochemistry*, no. January. Springer International Publishing, 2019.