

Optimalisasi Metode *RBFNN* Dengan *Fuzzy C-Means* Dalam Prediksi Import Barang Konsumsi Indonesia

I Dewa Gede Budiastawa¹, I Made Gede Sunarya^{2,*}, I Made Agus Wirawan³

Pascasarjana, Ilmu Komputer, Universitas Pendidikan Ganesha, Singaraja, Indonesia

Email: ¹budiastawa@uhnsugriwa.ac.id, ^{2,*}sunarya@undiksha.ac.id, ³imade.aguswirawan@undiksha.ac.id

Email Penulis Korespondensi: sunarya@undiksha.ac.id

Submitted 05-06-2025; Accepted 01-08-2025; Published 14-08-2025

Abstrak

Prediksi atau peramalan merupakan suatu tindakan yang bertujuan untuk mengetahui kejadian di masa depan berdasarkan indikator-indikator yang mempengaruhi suatu kejadian. Barang konsumsi merupakan produk maupun barang yang dibeli oleh orang maupun rumah tangga yang bertujuan untuk konsumsi secara langsung dalam artian tidak untuk tujuan produksi lebih lanjut. Berdasarkan hal tersebut maka perlu dilakukan penanganan yang serius untuk menjaga keadaan ekonomi Indonesia khususnya pada sektor industri. Prediksi nilai impor barang konsumsi merupakan suatu langkah dalam mengetahui nilai impor barang konsumsi pada periode selanjutnya sehingga pemerintah memiliki acuan dalam menentukan kebijakan. Dalam penelitian ini dilakukan prediksi nilai impor barang konsumsi berdasarkan faktor-faktor yang berpengaruh pada nilai impor barang konsumsi berdasarkan penelitian di bidang ekonomi. Penelitian ini menggunakan metode Radial Basis Function Neural Network (RBFNN) dengan menggunakan kombinasi pada metode Clustering yakni Fuzzy C-Means Clustering untuk meningkatkan performansi metode. Metode RBFNN merupakan metode terbaik yang digunakan dalam memprediksi data di masa yang akan datang berdasarkan penelitian sebelumnya serta metode FCM merupakan metode Clustering yang mampu mengatasi adanya ambiguitas dalam proses prediksi. Penelitian ini membuktikan bahwa metode Fuzzy C-Means efektif dalam mengoptimalkan kinerja metode Radial Basis Function Neural Network dengan perbandingan nilai MAPE pada setiap kombinasi yakni RBFNN – FCM 15.73%, RBFNN – K-Means 16.87% dan RBFNN – Random centroid 17.70%. Parameter learning rate berbanding lurus pada model RBFNN – FCM dimana semakin besar learning rate maka performansi model semakin baik yang menandakan model tidak perlu melakukan pembelajaran secara mendalam untuk mengenali pola data. Berbeda dengan parameter fuzzifikasi yang meningkatkan akurasi ketika nilai fuzzifikasi diturunkan yang menandakan bahwa model tidak memerlukan pendekatan yang sangat kabur untuk mengenali pola data. Arsitektur terbaik yakni 8 – 4 – 1 dengan nilai parameter fuzzifikasi 1.5, learning rate 0.3 dan threshold error 0.3 yang dihasilkan oleh kombinasi RBFNN dan FCM.

Kata Kunci: Prediksi; Impor Barang Konsumsi; RBFNN ; FCM; MAPE

Prediction or forecasting is an action that aims to find out future events based on indicators that influence an event. Consumer goods are products or goods purchased by people or households that are intended for direct consumption in the sense that they are not for further production purposes. Based on this, serious handling is needed to maintain the state of the Indonesian economy, especially in the industrial sector. Predicting the value of consumer goods imports is a step in finding out the value of consumer goods imports in the next period so that the government has a reference in determining policies. In this study, the prediction of the value of consumer goods imports was carried out based on factors that influence the value of consumer goods imports based on research in the field of economics. This study uses the Radial Basis Function Neural Network (RBFNN) method using a combination of Clustering methods, namely Fuzzy C-Means Clustering to improve method performance. The RBFNN method is the best method used in predicting future data based on previous research and the FCM method is a Clustering method that is able to overcome ambiguity in the prediction process. This study proves that the Fuzzy C-Means method is effective in optimizing the performance of the Radial Basis Function Neural Network method with a comparison of MAPE values in each combination, namely RBFNN - FCM 15.73%, RBFNN - K-Means 16.87% and RBFNN - Random centroid 17.70%. The learning rate parameter is directly proportional to the RBFNN - FCM model where the greater the learning rate, the better the model performance, indicating that the model does not need to do in-depth learning to recognize data patterns. In contrast to the fuzzification parameter which increases accuracy when the fuzzification value is lowered, indicating that the model does not require a very vague approach to recognize data patterns. The best architecture is 8 - 4 - 1 with a fuzzification parameter value of 1.5, a learning rate of 0.3 and a threshold error of 0.3 produced by a combination of RBFNN and FCM.

Keywords: Prediction; Consumer Goods Imports; RBFNN; FCM; MAPE

1. PENDAHULUAN

Perkembangan perekonomian suatu negara terus mengalami perkembangan yang disebabkan oleh banyak faktor, salah satunya jumlah konsumsi barang maupun jasa di suatu negara. Konsumsi merupakan pengeluaran yang diperlukan oleh seseorang atas barang maupun jasa dalam rangka memenuhi kebutuhan sehari-hari [1]. Kurangnya pasokan barang konsumsi baik dari segi kuantitas maupun kualitas di suatu negara akan mempengaruhi aktivitas impor barang konsumsi dari negara lain sehingga pemerintah maupun stakeholder produsen barang maupun jasa perlu melakukan adaptasi untuk menjaga kestabilan keadaan ekonomi negara. Impor barang konsumsi yang tidak stabil atau cenderung tinggi akan mempengaruhi ketahanan pangan di suatu negara dimana ketahanan pangan merupakan salah satu pilar penting dalam menjaga stabilitas nasional [2]. Selain mempengaruhi ketahanan pangan, impor barang konsumsi akan berpengaruh pada ketergantungan terhadap produk impor yang cenderung merugikan industri lokal. Prediksi maupun peramalan merupakan suatu aktivitas yang dilakukan untuk mengetahui kejadian di masa yang akan datang [3]. Prediksi impor barang konsumsi dapat dijadikan sebagai pendukung dalam pengambilan kebijakan untuk mengatur perdagangan Indonesia dalam menjaga stabilitas perekonomian.

Semakin berkembangnya ilmu pengetahuan, pengembangan pada metode yang dapat digunakan untuk memprediksi nilai di masa yang akan datang sangat banyak dikembangkan diantaranya metode regresi linier hingga metode yang menggunakan konsep kerja jaringan otak manusia atau jaringan syaraf tiruan. Terdapat beberapa penelitian terkait yang telah dilakukan oleh peneliti sebelumnya mengenai prediksi. Penelitian tentang prediksi nilai tukar rupiah terhadap US dolar menggunakan metode *RBFNN* [3] menghasilkan nilai akurasi sebesar 95,82% dengan arsitektur 6-7-1 dan *learning rate* 0,3 yang menunjukkan metode sangat baik dalam mengenali pola data.

Penelitian yang melakukan perbandingan metode juga dilakukan untuk menentukan metode terbaik dalam proses peramalan. Untuk mengetahui kinerja metode, analisis dilakukan dengan membandingkan metode Radial Basis Function dengan Multi *Layer* Perceptron terhadap beban tegangan Listrik [4]. Data yang dipergunakan adalah data *time series* konsumsi Listrik harian kota Baghdad. Hasil penelitian menunjukkan metode *Radial Basis Function Neural Network (RBFNN)* memberikan hasil prediksi yang lebih mendekati nilai actual dibandingkan dengan metode multi *Layer* perceptron neural network (MLPNN) berdasarkan nilai MSE minimum metode *RBFNN* $1,19 \times 10^{-4}$ sedangkan MSE dari MLPNN adalah $8,55 \times 10^{-4}$. Peneliti menyimpulkan model dengan metode *RBFNN* lebih cocok digunakan dalam proses peramalan STPLF.

Penelitian mengenai prediksi cuaca yang berfokus pada prediksi suhu dan kelembapan [5] juga melakukan perbandingan kinerja metode. Penelitian ini membandingkan metode Decision Tree, SVR dan Elastic Net Regression dimana hasil metode RBF lebih mendekati nilai aktual. Model *RBFNN* yang optimal diidentifikasi untuk perkiraan suhu, dengan 11 *hidden neuron* serta dengan 32 kali pelatihan memperoleh eror sebesar 0.0022. Sedangkan prediksi kelembapan, model *RBFNN* yang optimal memiliki 12 *centroid*, 10 *hidden neuron* dan 128 kali pelatihan memperoleh eror sebesar 0,0075.

Penelitian yang melakukan perbandingan metode untuk melakukan prediksi inflasi di kota Batam dilakukan pada tahun 2024 yang membandingkan metode ARMA dan *RBFNN* [6]. Penelitian ini menggunakan data *times series* inflasi di kota Batam. Analisis kinerja metode menggunakan MSE dan RMSE dimana pada metode ARMA diperoleh nilai MSE sebesar 0,246 dan RMSE sebesar 0,496. Sedangkan pada model *RBFNN* diperoleh nilai MSE sebesar 0,239 dan nilai RMSE sebesar 0,489 sehingga dapat disimpulkan bahwa metode *RBFNN* merupakan metode terbaik dalam prediksi nilai inflasi di kota Batam.


Pada metode *RBFNN* terdapat proses pemilihan pusat cluster sehingga seleksi pada nilai *centroid* atau pusat cluster data sangat penting [7]. Penelitian ini membandingkan penggunaan *RBFNN* tanpa bantuan metode *Clustering* dalam menentukan pusat data serta menggunakan metode *K-Means* dalam mengoptimalkan metode *RBFNN* dalam pemilihan pusat cluster data. Penelitian ini membuktikan bahwa penggunaan metode *Clustering* dalam pemilihan pusat cluster mampu meningkatkan kinerja metode dibandingkan dengan pemilihan pusat cluster secara acak. Hasil analisis menunjukkan nilai eror yang dihasilkan dengan penggunaan metode *K-Means* yakni 0,0389 sedangkan tanpa menggunakan metode *Clustering* menghasilkan eror sebesar 0,139 sehingga penggunaan metode *Clustering* sangat dianjurkan dalam metode *RBFNN*.

Penelitian mengenai prediksi yang menggunakan metode Radial Basis Function kerap menggunakan metode *K-Means* dalam proses penentuan nilai *centroid*. Penelitian sebelumnya membandingkan kinerja metode *K-Means* dan metode *Clustering* lainnya yakni metode *Fuzzy C-Means* pada *Clustering* daerah rawan kriminalitas di Kota Semarang [8]. Penelitian menghasilkan metode *Fuzzy C-Means* terbukti lebih unggul dari metode *K-Means* dengan perbandingan akurasi 71,23% pada *Fuzzy C-Means* dan 65,45% pada metode *K-Means*. Pada tahun 2022 dilakukan perbandingan metode FCM dan *K-Means* dalam *Clustering* daun melon [9]. Nilai validasi algoritma *K-Means* sebesar 0.5793 dan *Fuzzy C-Means* sebesar 0.8359, maka dengan ini dapat disimpulkan bahwa metode *Fuzzy C-Means* *Clustering* lebih baik.

Pada penelitian terdahulu dalam melakukan prediksi kerap menggunakan data *time series* satu data dimana data 12 bulan sebelumnya digunakan untuk memprediksi data di tahun mendatang. Pada penelitian ini dilakukan penelitian dalam memprediksi nilai impor barang konsumsi pada periode berikutnya dengan mempertimbangkan faktor-faktor yang berpengaruh terhadap perubahan nilai impor barang konsumsi sehingga diharapkan dapat memberikan rekomendasi nilai impor barang konsumsi pada periode mendatang dengan lebih akurat. Penelitian ini juga akan melakukan optimalisasi metode *Radial Basis Function Neural Network (RBFNN)* dengan metode *Fuzzy C-Means*. Penggunaan metode *Fuzzy C-Means* bertujuan untuk mengatasi kemungkinan adanya ambiguitas dalam *Clustering* data yang disebabkan oleh pola data yang tidak linier serta data multidimensi, dimana metode *Fuzzy C-Means* terbukti efektif dengan memberikan derajat keanggotaan pada setiap data untuk masing-masing cluster [9] dimana pada penelitian ini akan menggunakan 8 fitur yang diperoleh dari hasil analisis variabel berpengaruh pada impor barang konsumsi pada penelitian terdahulu.

2. METODOLOGI PENELITIAN

Penelitian ini akan melakukan optimisasi pada metode Radial Basis Function Neural Network dengan *Fuzzy C-Means*. Untuk memperoleh pembuktian bahwa metode *Fuzzy C-Means* efektif dalam proses optimalisasi maka dilakukan perbandingan dengan metode yang sering digunakan dalam proses pada metode *Radial Basis Function Neural Network* diantaranya metode *K-Means* dan metode pemilihan *centroid* secara acak. Adapun tahapan dalam penelitian ini disajikan pada Gambar 1 alur penelitian yang menggambarkan proses penelitian hingga analisis model terbaik yang dapat digunakan dalam prediksi impor barang konsumsi.



Gambar 1. Desain penelitian

Gambar 1 menunjukkan penelitian diawali dengan melakukan akuisisi data berdasarkan data berpengaruh. Data yang telah diperoleh dilakukan analisis secara bersama-sama untuk memastikan bahwa data benar-benar berpengaruh terhadap nilai impor barang konsumsi. Setelah dianalisis data diproses hingga memperoleh model terbaik dalam prediksi impor barang konsumsi.

2.1 Akuisisi Data

Penelitian ini menggunakan data yang merupakan setiap ekonomi makro yang telah dianalisis pada penelitian terdahulu pada bidang ekonomi serta diperoleh open source data diantaranya jumlah konsumsi nasional yang diakuisisi dari Badan Pusat Statistik. Kurs dollar Amerika Serikat yang diakuisisi dari Satu Data Kementerian Perdagangan. Jumlah penduduk yang diakuisisi dari Badan Pusat Statistik. Cadangan Devisa Negara yang diakuisisi dari Badan Pusat Statistik. Inflasi yang diakuisisi dari Satu Data Kementerian Perdagangan. Produk Domestik Bruto diakuisisi dari Satu Data Kementerian Perdagangan. Pendapatan negara berupa pajak diperoleh dari Badan Pusat Statistik.

2.2 Analisis Data Berpengaruh

Data yang akan dipergunakan pada penelitian ini berdasarkan penelitian pada bidang ekonomi [10][11][12][13][14]. Dataset yang digunakan pada penelitian ini yakni data berupa setiap ekonomi makro sebagai fitur yang meliputi jumlah konsumsi, nilai kurs rupiah terhadap dolar AS, jumlah penduduk, setiap devisa negara, inflasi, produk domestik bruto (PDB), pajak, nilai impor barang konsumsi Indonesia. Di bawah ini merupakan tabel hasil analisis korelasi secara bersama-sama antara fitur dan data target.

Tabel 1. Analisis data berpengaruh

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	R Square Change	Change Statistics			
						F Change	df1	df2	Sig. F Change
1	.723 ^a	.522	.461	227.484526	.522	8.601	8	63	<.001

a. Predictors: (Constant), Pajak, Cadangan_Devisa_Negara, Inflasi, Kurs, Jumlah_Konsumsi, PDB_Konstan, Jumlah_Penduduk, PDB_Berlaku

Tabel 1 menunjukan korelasi antara variabel prediktor dan variabel dependen dengan nilai $R = 0.723$ berada pada kategori kuat. Nilai R^2 0.522 menyatakan bahwa variabel dependen dapat dijelaskan oleh model serta Sig. F Change $< .001$ menyatakan model secara statistik signifikan sehingga prediktor secara bersama-sama berpengaruh terhadap variabel dependen.

2.3 Preprocessing Data


Preprocessing data dilakukan dengan melakukan interpolasi pada data yang diperoleh tahunan dan triwulanan menjadi data bulanan dimana data yang bersifat linier diproses dengan metode interpolasi linier serta data non-linier diproses dengan metode interpolasi *cubic* kemudian dilakukan normalisasi data menjadi bentuk yang lebih sederhana. Proses normalisasi data dilakukan untuk meringankan proses komputasi dengan membuat data menjadi lebih sederhana. Pada penelitian ini digunakan metode normalisasi min-max. metode normalisasi min-max merupakan proses normalisasi yang dilakukan dengan transformasi linier terhadap data asli.

2.4 Clustering Data

Pada tahap ini data dikelompokkan menjadi beberapa cluster yang telah ditentukan serta dilakukan proses perhitungan untuk memperoleh pusat cluster yang optimal. Penelitian ini berasumsi bahwa metode *Fuzzy C-Means* dapat mengoptimalkan metode *RBNN* karena metode *Fuzzy C-Means* dapat menangani ambiguitas dalam proses *Clustering* dengan mengedepankan konsep derajat keanggotaan bukan kedekatan jarak seperti metode *Clustering* lainnya [15]. Metode *Fuzzy C-Means* lebih baik dari metode *Clustering* lainnya [9]. Untuk memperoleh pembuktian maka akan dilakukan kombinasi metode *RBNN* dengan metode *Fuzzy C-Means*, *RBNN* dengan *K-Means* serta *RBNN* dengan pemilihan *centroid* secara acak.

2.5 Prediksi RBNN

Dalam proses prediksi terdapat dua proses utama yakni training dan testing. Training data memiliki tujuan untuk mempelajari pola data berdasarkan parameter *input* dan parameter target. Parameter *input* meliputi jumlah konsumsi, nilai kurs rupiah terhadap dolar AS, jumlah penduduk, Cadangan devisa negara, inflasi, produk domestik bruto (PDB), pendapatan negara berupa pajak. Parameter target yakni nilai import barang konsumsi Indonesia. Training data dilakukan dengan 3 model yakni model pertama menggunakan kombinasi metode *RBNN* dan *Fuzzy C-Means* serta menggunakan kombinasi pada parameter *input* jumlah cluster, *learning rate*, parameter fuzzy dan toleransi konvergensi. Model kedua menggunakan kombinasi metode *RBNN* dengan metode *K-Means Clustering* serta dilakukan kombinasi pada parameter *input* berupa jumlah cluster, *learning rate*. Model ketiga kombinasi metode *RBNN* dengan pemilihan *centroid* setiap acak. *RBNN* memiliki sifat feedforward dimana signal akan bergerak dari *input Layer* kemudian akan bergerak menuju *hidden Layer* dan akan mencapai unit keluaran atau *output Layer* [16]. Setiap pola data akan dipelajari dan akan dilakukan pembaharuan bobot untuk memaksimalkan kinerja model yang digunakan. *RBNN* menggunakan fungsi aktivasi gaussian dimana fungsi aktivasi memiliki fungsi untuk mengaktifkan *neuron* [17] untuk mempelajari pola data. Pada tahap testing dilakukan proses penjumlahan terbobot berdasarkan bobot terbaru yang diperoleh dari hasil training data [18]. Gambar 2 merupakan arsitektur jaringan *Radial Basis Function Neural Network* dengan 8 *input*, n kombinasi *hidden neuron* serta 1 *output* yang digunakan dalam penelitian ini.



Gambar 2. Arsitektur jaringan

Gambar 2 menunjukkan penelitian ini menggunakan 3 layer dimana terdiri dari 8 neuron pada input layer, n neuron pada hidden layer dimana pada tahap pengujian akan dilakukan pengujian dengan penggunaan kombinasi jumlah hidden neuron serta 1 neuron pada output layer. Penelitian ini menggunakan 1 hidden layer sesuai dengan karakteristik metode *Radial Basis Function Neural Network (RBFNN)*.

2.6 Evaluasi

Evaluasi hasil penelitian dilakukan dengan metode *Mean Absolute Percentage error (MAPE)*. Dengan kata lain *MAPE* melakukan perhitungan kesalahan absolut yang dihasilkan pada setiap proses pelatihan dan membagi dengan nilai observasi yang nyata untuk periode tersebut, kemudian menghitung rata-rata persentase kesalahan absolut tersebut (Budiasatwa et al., 2019). Besaran nilai *MAPE* akan dipengaruhi oleh jumlah data [19]. Error merupakan nilai selisih antara nilai aktual dan nilai prediksi, rata-rata error akan dihitung sehingga akan memperoleh persentase nilai error. Model yang menghasilkan nilai persentase error terkecil akan dikategorikan sebagai model terbaik. Analisis performansi model dengan menggunakan *MAPE* dapat dikategorikan menjadi 4 (empat) penafsiran [20]. Tabel 2 menyajikan kategori nilai *MAPE* berdasarkan rentang nilai.

Tabel 2. Penafsiran nilai *MAPE*

No	Rentang	Kategori
1	< 10%	Sangat akurat
2	10% - 20%	Baik
3	20% - 50%	Wajar
4	> 50%	Tidak akurat

3. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan data sekunder yang diperoleh dari Badan Pusat Statistika, Kementerian Perdagangan serta Bank Indonesia. Adapun data yang digunakan yakni jumlah konsumsi, kurs, jumlah penduduk, cadangan devisa negara, inflasi, PDB konstan, PDB berlaku dan pajak dengan variabel target yakni impor barang konsumsi. Data yang dipergunakan merupakan data bulanan dari tahun 2018 hingga tahun 2023 dengan jumlah data 72 pasang. Data akan dinormalisasi dan kemudian akan diproses pada kombinasi model. Adapun model yang akan diujikan yakni kombinasi *RBFNN* dengan *FCM*, *RBFNN* dengan *K-Means* serta *RBFNN* dengan pemilihan pusat data secara acak.

3.1 Pengujian terhadap kombinasi *RBFNN* dengan 3 model *Clustering*


Pengujian dilakukan dengan mengkombinasikan metode *Radial Basis Function Neural Network* dengan ketiga metode *Clustering* untuk mengetahui metode yang lebih unggul serta dapat mengoptimalkan kinerja metode *Radial Basis Function Neural Network*. Tabel 3 menyajikan hasil pengujian terhadap kombinasi *RBFNN* dengan 3 model *Clustering*.

Tabel 3. Hasil pengujian *RBFNN* dengan 3 model *Clustering*

Skenario Ke-	Metode <i>Clustering</i>	Neuron	Learning Rate	<i>MAPE</i> (%)	Akurasi (%)
1	<i>K-Means</i>	2	0.1	17.979	82.021
2	<i>Random</i>	2	0.1	17.895	82.105
3	<i>FCM</i>	2	0.1	17.795	82.205
4	<i>K-Means</i>	2	0.2	17.726	82.274
5	<i>Random</i>	2	0.2	17.752	82.248
6	<i>FCM</i>	2	0.2	17.657	82.343
7	<i>K-Means</i>	2	0.3	17.508	82.492
8	<i>Random</i>	2	0.3	17.861	82.139
9	<i>FCM</i>	2	0.3	17.511	82.489
10	<i>K-Means</i>	4	0.1	16.869	83.131
11	<i>Random</i>	4	0.1	17.701	82.299
12	<i>FCM</i>	4	0.1	16.575	83.425
13	<i>K-Means</i>	4	0.2	17.247	82.753
14	<i>Random</i>	4	0.2	17.979	82.021
15	<i>FCM</i>	4	0.2	16.081	83.919
16	<i>K-Means</i>	4	0.3	17.891	82.109
17	<i>Random</i>	4	0.3	18.365	81.635
18	<i>FCM</i>	4	0.3	15.739	84.261
19	<i>K-Means</i>	6	0.1	17.383	82.617
20	<i>Random</i>	6	0.1	18.249	81.751
21	<i>FCM</i>	6	0.1	17.093	82.907
22	<i>K-Means</i>	6	0.2	17.093	82.907
23	<i>Random</i>	6	0.2	18.253	81.747

Skenario Ke-	Metode Clustering	Neuron	Learning Rate	MAPE (%)	Akurasi (%)
24	FCM	6	0.2	17.163	82.837
25	K-Means	6	0.3	20.005	79.995
26	Random	6	0.3	18.181	81.819
27	FCM	6	0.3	17.17	82.83
28	K-Means	8	0.1	17.292	82.708
29	Random	8	0.1	17.747	82.253
30	FCM	8	0.1	17.243	82.757
31	K-Means	8	0.2	17.243	82.757
32	Random	8	0.2	18.372	81.628
33	FCM	8	0.2	17.114	82.886
34	K-Means	8	0.3	17.75	82.25
35	Random	8	0.3	19.505	80.495
36	FCM	8	0.3	16.816	83.184

Tabel 3 menunjukkan bahwa kombinasi metode *Radial Basis Function Neural Network* dengan *Fuzzy C-Means* lebih unggul dari pada kombinasi metode *Radial Basis Function Neural Network* dengan *K-Means* dan kombinasi *Radial Basis Function Neural Network* dengan model pemilihan *centroid* data secara acak dengan nilai *Mean Absolute Percentage Error* sebesar 15,739% serta keakuratan model sebesar 84,261% dengan arsitektur jaringan *Radial Basis Function Neural Network* 8 – 4 – 1 dan *learning rate* 0,3.



Gambar 3. Pengaruh *hidden neuron* dan *learning rate*

Gambar 3 menunjukkan bahwa semakin besar atau semakin kecilnya jumlah cluster ataupun *hidden neuron* tidak memberikan pengaruh yang signifikan terhadap performansi model. Terdapat peningkatan pada perubahan jumlah cluster atau *neuron* dari 2 menuju ke 4, namun performansi jaringan kembali menurun pada penambahan jumlah *neuron* dari 4 ke 6 sehingga penambahan *neuron* tidak memberikan pengaruh terhadap performansi model pada skenario pengujian. Perubahan *learning rate* berpengaruh terhadap performansi model. Pada kombinasi metode *Radial Basis Function Neural Network* dengan metode *Fuzzy C-Means* *learning rate* memiliki pengaruh positif dimana peningkatan nilai *learning rate* meningkatkan akurasi model dimana semakin besar nilai *learning rate* memiliki arti laju pembelajaran semakin besar dimana model tidak melakukan pembelajaran secara mendalam untuk mengenal pola data dalam hal ini model melakukan pembaharuan bobot secara agresif tidak perlahan. Metode *Fuzzy C-Means* merupakan tipe soft *Clustering* dimana metode mampu mengadaptasi data dengan lebih teliti dimana pada metode *Fuzzy C-Means* setiap data tidak dikelompokkan secara mutlak ke satu kelompok seperti metode *Clustering* lainnya dimana setiap data diberikan derajat keanggotaan pada setiap pusat cluster, perubahan derajat keanggotaan pada metode *Fuzzy C-Means* dilakukan secara perlahan. Berbeda dengan kombinasi metode *Radial Basis Function Neural Network* dengan *K-Means* dan *Radial Basis Function Neural Network* dengan pemilihan *centroid* data secara *random* dimana dari hasil penelitian menunjukkan bahwa semakin besar nilai *learning rate* maka performansi model semakin menurun dimana pada kedua model *Clustering* ini memerlukan pembelajaran yang mendalam sehingga semakin kecil *learning rate* atau laju pembelajaran maka semakin tinggi performansi model.


3.2 Pengujian Dengan Kombinasi Parameter *Fuzzy C-Means*

Pengujian dengan kombinasi pada parameter *Fuzzy C-Means* bertujuan untuk mencari arsitektur dan kombinasi terbaik dari optimalisasi metode *Radial Basis Function Neural Network* dengan *Fuzzy C-Means*. Arsitektur jaringan *Radial Basis Function Neural Network* yang digunakan merupakan arsitektur terbaik pada pengujian sebelumnya yakni 7 – 4 – 1, adapun parameter pada metode *Fuzzy C-Means* yang digunakan pada pengujian ini yakni parameter fuzzifikasi (*m*) dan *threshold error* yang merupakan toleransi *error* sebagai batas dalam melakukan pembelajaran. Tabel 3 menyajikan hasil pengujian pada kombinasi parameter metode *Fuzzy C-Means*.

Tabel 3. Pengujian pada konfigurasi parameter *Fuzzy C-Means*


Skenario Ke-	Fuzifikasi	Threshold Error	MAPE (%)	Akurasi (%)
1	1.5	0.1	15.743	84.257
2	2	0.1	15.739	84.261
3	2.5	0.1	15.738	84.262
4	3	0.1	18.466	81.534
5	3.5	0.1	18.489	81.511
6	1.5	0.2	15.733	84.267
7	2	0.2	15.756	84.244
8	2.5	0.2	17.164	82.836
9	3	0.2	18.095	81.905
10	3.5	0.2	17.936	82.064
11	1.5	0.3	15.724	84.276
12	2	0.3	15.807	84.193
13	2.5	0.3	17.474	82.526
14	3	0.3	18.01	81.99
15	3.5	0.3	17.936	82.064


Tabel 3 menunjukkan performansi terbaik dengan nilai eror 15,724% serta nilai keakuratan 84,276% dihasilkan dengan kombinasi arsitektur jaringan 7 – 4 – 1 serta parameter fuzzifikasi (m) sebesar 1,5 dan toleransi error 0,3. Gambar 4 menyajikan grafik pengaruh parameter fuzzifikasi (m) terhadap performansi model.



Gambar 4. Pengaruh parameter fuzzifikasi

Gambar 4 menunjukkan bahwa semakin besar nilai fuzzifikasi maka akan semakin menurun performansi dari model yang digunakan. Semakin besar nilai fuzzifikasi menandakan semakin *fuzzy* atau semakin kabur metode dalam melakukan pemrosesan suatu data, pada pengujian model dengan melakukan konfigurasi pada parameter fuzzifikasi mengindikasikan bahwa diperlukan pemrosesan data secara detail untuk mengoptimalkan kinerja model. Berdasarkan Tabel 3 menunjukkan bahwa model paling optimal diperoleh dengan penggunaan nilai fuzzifikasi 1,5 yang merupakan nilai paling kecil diantara parameter fuzzifikasi dengan nilai error sebesar 15,724% sedangkan nilai performansi paling rendah diperoleh dengan kombinasi parameter fuzzifikasi 3,5 yang merupakan nilai paling tinggi pada parameter fuzzifikasi dengan nilai error sebesar 18,489%. Gambar 5 menyajikan pengaruh parameter *threshold error* atau batasan error terhadap performansi model.






Gambar 5. Pengaruh parameter threshold error

Gambar 5 menunjukkan bahwa toleransi *error* tidak memberikan dampak yang signifikan terhadap performansi model dimana semakin tinggi batasan *error* tidak selalu menaikkan performansi model dan sebaliknya dimana pada penggunaan parameter fuzzifikasi 1.5, 3 dan 3.5 semakin besar nilai fuzzifikasi maka performansi model semakin baik, namun ketika penggunaan parameter fuzzifikasi 2 dan 2.5 performansi model menurun ketika toleransi *error* dinaikkan.

3.3 Analisis Kinerja Model

Kombinasi metode *Radial Basis Function Neural Network* dengan *Fuzzy C-Means* lebih baik dari kombinasi metode *Radial Basis Function Neural Network* dengan *K-Means* maupun dengan pemilihan *centroid* secara acak dalam prosesnya. Gambar 6 dan Tabel 4 menyajikan perbandingan performansi kombinasi metode *Radial Basis Function Neural Network* dengan metode *Fuzzy C-Means*, *K-Means*, dan pemilihan *centroid* secara acak.



Gambar 6. Performansi kombinasi metode optimisasi

Tabel 4. Perbandingan kombinasi metode

No	Model	Arsitektur	Tertinggi (%)	
			MAPE	AKURASI
1	<i>RBNN – Random centroid</i>	8 – 8 – 1	17.701	82.299
2	<i>RBNN – K-Means</i>	8 – 4 – 1	16.869	83.131
3	<i>RBNN – Fuzzy C-Means</i>	8 – 4 – 1	15.739	84.261

4. KESIMPULAN

Berdasarkan hasil pengujian sesuai dengan skenario pengujian metode *Radial Basis Function Neural Network* dapat dioptimalisasi dengan metode *Fuzzy C-Means* dimana penggunaan metode *Fuzzy C-Means* pada metode *Radial Basis Function Neural Network* menghasilkan performa yang lebih baik dari pada penggunaan metode *K-Means* dan pemilihan *centroid* data secara acak untuk prediksi impor barang konsumsi dengan data tahun 2018 hingga 2023 dengan 72 pasang data serta 8 fitur. Penggunaan metode *Fuzzy C-Means* bertujuan untuk mengantisipasi ambiguitas dalam proses *clustering* dimana ambiguitas pada proses *clustering* disebabkan oleh data yang terdiri dari banyak fitur serta pola data yang tidak linier. Penelitian ini menghasilkan model yang dapat digunakan untuk melakukan prediksi impor barang konsumsi dengan variabel independen berjumlah 8 yang meliputi jumlah konsumsi, kurs, jumlah penduduk, cadangan devisa negara, inflasi, produk domestik bruto konstan, produk domestik bruto berlaku serta pajak. Arsitektur terbaik yang diperoleh pada pengujian yakni 8 – 4 – 1 dimana terdiri dari 8 *neuron input*, 4 *hidden neuron* serta 1 *neuron output* yang dihasilkan oleh kombinasi metode *Radial Basis Function Neural Network* dengan metode *Fuzzy C-Means* dengan nilai *MAPE* 15.739% dan akurasi model sebesar 84.261% sedangkan performansi terendah dihasilkan oleh kombinasi antara *Radial Basis Function Neural Network* dengan metode *K-Means* dengan nilai *MAPE* 20.005% dan akurasi model 79.995% dengan arsitektur jaringan 8 – 6 – 1 yang terdiri dari 8 *neuron input*, 6 *neuron* tersembunyi dan 1 *neuron output*. Parameter

fuzzifikasi atau bobot fuzzy memberikan pengaruh yang signifikan terhadap performansi model dimana semakin kecil parameter fuzzifikasi maka akan semakin baik akurasi yang dihasilkan yang mengindikasikan model tidak terlalu baur untuk mengenali pola data selain itu parameter *threshold error* tidak memberikan pengaruh yang signifikan dimana semakin besar atau semakin kecil *threshold* yang diberikan memiliki dampak yang berbeda untuk setiap skenario, namun skenario terbaik diperoleh dengan nilai fuzzifikasi 1,5 dan *threshold* 0,3 dimana parameter fuzzifikasi paling rendah dan nilai *threshold* paling tinggi.

REFERENCES

- [1] M. C. B. Umanailo, M. Nawawi, and S. Pulhehe, "Konsumsi Menuju Konstruksi Masyarakat Konsumtif," *SIMULACRA: JURNAL SOSIOLOGI*, vol. 1, no. 2, Nov. 2018, doi: 10.21107/sml.v1i2.4995.
- [2] B. E. Supriyanto, "Dampak Kebijakan Impor terhadap Ketahanan Pangan di Indonesia," *DIItjen Perbendaharaan Kemenkeu RI KPPN Watampone*.
- [3] I. D. G. Budiastawa, I. W. Santiyasa, and C. R. A. Pramatha, "Prediksi Dan Akurasi Nilai Tukar Mata Uang Rupiah Terhadap US Dolar Menggunakan Radial Basis Function Neural Network," *Jurnal Elektronik Ilmu Komputer Udayana*, vol. 7, no. 4, pp. 309–317, 2019.
- [4] M. O. Ali et al., "Radial Basis Function Neural Networks-Based Short Term Electric Power Load Forecasting For Super High Voltage Power Grid," 2022.
- [5] V. Veeramsetty, P. Kiran, M. Sushma, and S. R. Salkuti, "Weather Forecasting Using Radial Basis Function Neural Network in Warangal, India," *Urban Science*, vol. 7, no. 3, Sep. 2023, doi: 10.3390/urbansci7030068.
- [6] W. Reza, F. Christin, H. Buan, and S. N. Abdussamad, "Comparison Of Radial Basis Function Neural Networks (RBFNN) And Autoregressive Moving Average (ARMA) Algorithms On Inflation Rate Prediction Models In Batam City-Widya Reza et.al Comparison Of Radial Basis Function Neural Networks (RBFNN) And Autoregressive Moving Average (ARMA) Algorithms On Inflation Rate Prediction Models In Batam City 1*," *Informatika dan Sains*, vol. 14, no. 02, p. 2024, doi: 10.58471/infosains.v14i02.
- [7] M. Yogy Kurniawan, F. Hafidh, and dan Al Fath Riza Kholdani, *Prosiding Hasil-Hasil Penelitian Tahun 2016 Seleksi Nilai Center Radial Basis Function Neural Network Menggunakan K-Means Pada Data Time series*.
- [8] H. S. Firdaus, A. L. Nugraha, B. Sasmito, M. Awaluddin, and C. A. Nanda, "Perbandingan Metode Fuzzy C-Means Dan K-Means Untuk Pemetaan Daerah Rawan Kriminalitas Di Kota Semarang," 2021.
- [9] A. Siregar, A. Buono, and K. Priandana, "Perbandingan Algoritma K-Means dan Fuzzy C-Means untuk Clustering Citra Daun Melon," *Building of Informatics, Technology and Science (BITS)*, vol. 4, no. 3, Dec. 2022, doi: 10.47065/bits.v4i3.2534.
- [10] P. S. W. Richart and L. G. Meydianawati, "Faktor-Faktor Yang Berpengaruh Terhadap Impor Barang Konsumsi Di Indonesia," *E-Jurnal EP Unud*, vol. 12, no. 3, pp. 613–623, 2014.
- [11] N. K. Mutiasari and G. B. Indrajaya, "Analisis Faktor-Faktor Yang Mempengaruhi Impor Beras Di Indonesia," *E-Jurnal EP Unud*, vol. 11, no. 05, pp. 1699–1721, 2020.
- [12] R. Ardian, S. Iqbal, and S. Muljaningsih, "Analisis faktor-faktor yang mempengaruhi impor gula di Indonesia," *Online) KINERJA: Jurnal Ekonomi dan Manajemen*, vol. 19, no. 1, p. 29, 2022, doi: 10.29264/jkin.v19i1.10880.
- [13] I. B. Prakoso and M. I. Hasmarini, "Determinan Impor Barang Konsumsi Indonesia," *Ekonomis: Journal of Economics and Business*, vol. 6, no. 2, p. 836, Sep. 2022, doi: 10.33087/ekonomis.v6i2.662.
- [14] M. Juni, "Faktor-Faktor Yang Berpengaruh Terhadap Impor Barang Konsumsi Di Indonesia," *Jurnal Inovasi Penelitian*, vol. 2, no. 12, pp. 3879–3886, 2022.
- [15] J. Saputra, M. Iqbal Al Aksha, and L. Maryani, "Analisis Perbandingan Efektivitas Metode Fuzzy C-Means dan K-Means dalam Mengelompokkan Buku Berdasarkan Frekuensi Peminjaman di Perpustakaan SMKN 1 Mandau," *EXPLORE*, vol. 14, no. 2, pp. 87–92, 2024.
- [16] D. R. Rochmawati, "Prediksi Cuaca Dengan Jaringan Syaraf Tiruan Menggunakan Python," *Jurnal Teknologi Komputer dan Informatika*, vol. 2, no. 2, pp. 162–171, 2024.
- [17] M. Agustin and T. Prahasto, "Penggunaan Jaringan Syaraf Tiruan Backpropagation Untuk Seleksi Penerimaan Mahasiswa Baru Pada Jurusan Teknik Komputer Di Politeknik Negeri Sriwijaya," *Jurnal Sistem Informasi Bisnis*, vol. 2, pp. 89–97, 2012.
- [18] S. Haykin, *Neural Networks - A Comprehensive Foundation*, vol. 9, 2005.
- [19] Md. W. Aditya, I. N. Sukajaya, and I. Gede Aris Gunadi, "Forecasting Jumlah Pasien DBD di BRSUD Kabupaten Tabanan Menggunakan Metode Regresi Linier," *Bali Medika Jurnal*, vol. 10, no. 1, pp. 1–12, 2023, doi: 10.36376/bmj.v9i3.
- [20] T. Mariani and I. Rosyida, "Implementasi Metode Double Exponential Smoothing untuk Peramalan Luas Panen Padi di Kabupaten Pati dengan Bantuan Software Minitab 16," *PRISMA, Prosiding Seminar Nasional Matematika*, vol. 6, pp. 707–713, 2023, [Online]. Available: <https://journal.unnes.ac.id/sju/index.php/prisma/>