

# Peramalan Beban Jangka Panjang pada Gardu Induk Bangil dengan Metode Generalized Regression Neural Network

Anggit Fathurrozi<sup>1</sup>, Guido Dias Kalandro<sup>2</sup>, Ali Rizal Chaidir<sup>3</sup>, Suprihadi Prasetyono<sup>4</sup>, Moch Gozali<sup>5</sup>

Program Studi Teknik Elektro,  
Fakultas Teknik,  
Universitas Jember, Jember  
<sup>2</sup>guidokalandro89@unej.ac.id

## Abstract

Given the rising energy demands, the existing electrical infrastructure, notably distribution transformers 3 and 4 at the Bangil Substation, faces the risk of overload. Accurate load forecasting is imperative to inform timely interventions like transformer replacement. This study aims to forecast the load for Transformers 3 and 4 at the Bangil Substation using 2 difference methods, comparing Feed Forward Backpropagation Neural Network (FFBNN) and Generalized Regression Neural Network (GRNN). This research also evaluates potential transformer overloads based on forecasted peak loads. This research employed an STL (Seasonal-Trend Decomposition using LOESS) Decomposition to decompose monthly peak load data in each transformer into trend, seasonal and residual components and developing forecasting model for each transformer trend component data. Simultaneously, separate forecasting models were developed for the Gross Regional Domestic Product (GRDP) and the Industrial Sector of GRDP. The forecasted trend components from the transformer data were combined with the GRDP and Industrial Sector of GRDP forecasts using an approximation model. This approach aimed to approximate the monthly peak load more accurately, incorporating both energy demand trends and economic indicators. The forecasting models' accuracy was gauged using Mean Absolute Percentage Error (MAPE) and Mean Absolute Error (MAE). The analysis indicates that Transformer 3 is projected to reach overload by August 2038, with a forecasted peak load of 1407.7465 A. Conversely, Transformer 4 is expected to experience overload by February 2028, with a peak load of 1269.2173 A. FFBNN exhibited superior accuracy for Transformer 3, recording a MAPE of 10.522% and MAE of 74.204. In contrast, GRNN displayed better performance for Transformer 4, achieving a MAPE of 6.051% and MAE of 46.557. Timely interventions, such as transformer replacement, are essential to mitigate potential overloads. The research underscores the importance of employing tailored forecasting approaches, emphasizing the peak load transformer data with economic indicators for more precise load approximations

**Keywords:** *Load Forecasting, STL, Distribution Transformer*

## Abstrak

Dengan meningkatnya permintaan energi, infrastruktur listrik yang ada, terutama transformator distribusi 3 dan 4 di Gardu Induk Bangil, menghadapi risiko kelebihan beban. Peramalan beban yang akurat sangat penting untuk memberi informasi pada intervensi yang tepat waktu seperti penggantian transformator. Penelitian ini bertujuan untuk meramalkan

beban untuk Transformator 3 dan 4 di Gardu Induk Bangil menggunakan 2 metode kemudian membandingkan antara metode Feed Forward Backpropagation Neural Network (FFBNN) and Generalized Regression Neural Network (GRNN). Penelitian ini juga mengvaluasi potensi overload trafo berdasarkan forecasted peak loads. Penelitian ini menggunakan Dekomposisi STL (Seasonal-Trend Decomposition using LOESS) untuk mendekomposisi data puncak bulanan pada setiap transformator menjadi komponen tren, musiman, dan residu, serta mengembangkan model peramalan untuk data komponen tren setiap transformator. Secara bersamaan, model peramalan terpisah dikembangkan untuk Produk Domestik Regional Bruto (PDRB) dan Sektor Industri PDRB. Komponen tren yang diperamalkan dari data transformator digabungkan dengan peramalan PDRB dan Sektor Industri PDRB menggunakan model pendekatan. Pendekatan ini bertujuan untuk mendekati beban puncak bulanan dengan lebih akurat, menggabungkan tren permintaan energi dan indikator ekonomi. Akurasi model peramalan dinilai menggunakan Mean Absolute Percentage Error (MAPE) dan Mean Absolute Error (MAE). Analisis menunjukkan bahwa Transformer 3 diproyeksikan mencapai kelebihan beban pada Agustus 2038, dengan beban puncak yang diperkirakan sebesar 1407.7465 A. Sebaliknya, Transformer 4 diperkirakan akan mengalami kelebihan beban pada Februari 2028, dengan beban puncak sebesar 1269.2173 A. FFBNN menunjukkan akurasi yang superior untuk Transformer 3, dengan MAPE sebesar 10.522% dan MAE sebesar 74.204. Sebaliknya, GRNN menampilkan kinerja yang lebih baik untuk Transformer 4, mencapai MAPE sebesar 6.051% dan MAE sebesar 46.557. Intervensi tepat waktu, seperti penggantian transformator, sangat penting untuk mengurangi potensi kelebihan beban. Penelitian ini menekankan pentingnya menggunakan pendekatan peramalan yang disesuaikan, yang berfokus pada data beban puncak transformator dengan indikator ekonomi untuk prediksi beban yang lebih tepat.

**Kata kunci:** Peramalan Beban, STL, Transformator distribusi

## 1. Pendahuluan

Listrik adalah salah satu sumber energi yang sangat dibutuhkan oleh manusia. Peningkatan konsumsi sumber energi dalam hal ini energi listrik dapat ditunjukkan pada Gardu Induk Bangil sebagai salah satu contohnya. Konsumsi energi listrik di Gardu Induk Bangil menunjukkan tren peningkatan sejak 2013. Transformator distribusi 4 dan 3, setelah mengalami uprating pada 2017 dan 2012, secara berturut-turut mencatat beban puncak tertinggi pada Oktober 2021 (45,6497 MVA) dan Mei 2022 (36,955 MVA). Peningkatan ini menandai tantangan dalam manajemen beban dan efisiensi transformator di lokasi tersebut.

Peningkatan beban jika tidak diantisipasi akan berdampak buruk terhadap sistem tenaga listrik. Karena energi listrik adalah bentuk energi yang sulit disimpan, sehingga dalam waktu yang sama jumlah energi yang diproduksi harus sesuai dengan jumlah energi yang dikonsumsi [1]. Ketidaksesuaian produksi dan konsumsi menyebabkan masalah yaitu *overload* dan *oversupply* pada sistem tenaga listrik. Karena penambahan kapasitas sistem tenaga listrik membutuhkan waktu yang lama, sehingga pertumbuhan beban di masa depan perlu diprediksi. Metode matematika yang digunakan untuk memprediksi pertumbuhan beban listrik disebut dengan peramalan beban (*load forecasting*) [2]. Peramalan beban yang akurat juga dapat membuat sistem tenaga listrik yang lebih ekonomis, aman dan handal [3]. Peramalan beban dapat dibagi menjadi 3 jenis yaitu peramalan beban jangka pendek, menengah dan panjang [4], terdapat banyak faktor yang berpengaruh terhadap peramalan beban, untuk peramalan beban jangka panjang faktor yang berpengaruh adalah faktor-faktor eksternal yang terjadi dalam jangka waktu yang lama seperti pertumbuhan penduduk dan ekonomi [5]. Tetapi karena kurangnya

ketersediaan data, pembuatan model peramalan beban juga bisa hanya menggunakan data historisnya karena data tersebut merupakan representasi dari pengaruh-pengaruh eksternal [6].

Peramalan beban secara umum dibagi menjadi 2 metode yaitu menggunakan metode parametrik seperti penggunaan regresi linier [7], dan metode kecerdasan buatan (AI). Metode dengan kecerdasan buatan dapat diklasifikasikan lebih lanjut yaitu berdasarkan *neural network* dan *fuzzy-logic*. Terdapat beberapa jenis metode *neural network* yang biasa digunakan dalam peramalan beban salah satunya yaitu dengan *Generalized Regression neural network* (GRNN) dan *Feed Forward Backpropagation Neural Network* (FFBNN). Penelitian menunjukkan untuk peramalan beban jangka Panjang GRNN memiliki akurasi yang lebih tinggi dibandingkan dengan metode FFBNN [1], tapi di penelitian lain menunjukkan hal sebaliknya, yaitu penelitian peramalan beban jangka pendek menunjukkan FFBNN dengan fungsi aktivasi GDM memiliki akurasi yang lebih tinggi dibandingkan GRNN [8]. Perbedaan kedua hasil penelitian tersebut menunjukkan perlu adanya eksplorasi lebih lanjut mengenai perbandingan antara metode *generalized regression neural network* (GRNN) dan *feed forward backpropagation neural network* (FFBNN) untuk peramalan beban. Tujuan dari penelitian ini mengetahui perbandingan tingkat akurasi peramalan beban dengan menggunakan metode *generalized regression network* dan *backpropagation neural network*.

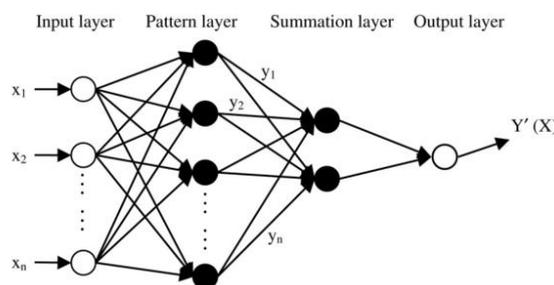
## 2. Tinjauan Pustaka

### 2.1. Generalized Regression Neural Network (GRNN)

*Generalized Regression Neural Network* (GRNN) adalah jenis model *neural network* yang merupakan modifikasi dari *Radial Basis Neural Network* (RBNN) [9]. GRNN sering digunakan untuk mencari fungsi aproksimasi dari data-data non-linier. Prediksi yang dilakukan oleh jaringan GRNN dapat dinyatakan melalui Persamaan 1.

$$Y(x) = \frac{\sum_{k=1}^N y_k K(x, x_k)}{\sum_{k=1}^N K(x, x_k)} \quad (1)$$

$Y(x)$  adalah nilai prediksi dari GRNN.  $y_k$  adalah bobot aktivasi (*activation weight*) untuk lapisan pola (*pattern*) neuron K.  $K(x, x_k)$  adalah *radial basis function* (RBF). Ilustrasi arsitektur *generalized regression neural network* dapat dilihat pada Gambar 1



Gambar 1 Arsitektur Generalized Regression Neural Network

Gambar 1 menunjukkan struktur jaringan GRNN yang terdiri dari 4 lapisan (*layer*), yaitu lapisan masukan, lapisan basis radial atau lapisan pola (*pattern*) atau lapisan tersembunyi (*hidden*), lapisan penggabungan (*summation*), dan lapisan keluaran. Lapisan masukan pada GRNN adalah lapisan (*layer*) yang berfungsi menerima data masukan ke jaringan GRNN. Lapisan masukan terdiri dari beberapa *node* (simpul) yang jumlahnya sama dengan jumlah dataset yang digunakan. Lapisan masukan meneruskan data yang

sudah diberi *weight* (bobot) ke lapisan pola (*pattern*). GRNN menggunakan parameter penyebaran (*spread parameter*) yang dilambangkan dengan  $\sigma$  (sigma). Nilai dari parameter penyebaran adalah antara 0 hingga 1, besarnya parameter tersebut berpengaruh dengan tingkat generalisasi dari GRNN [10].

**2.2. Feed Forward Backpropagation Neural Network (FFBNN)**

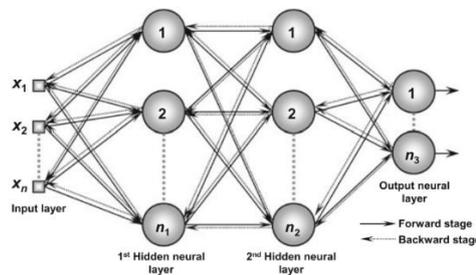
*Backpropagation neural network* adalah jenis algoritma jaringan syaraf tiruan yang digunakan pada *model Multi-layer Perceptron (MLP)*. Algoritma ini juga sering disebut sebagai *Generalized Delta Rule* [11]. *Backpropagation* biasanya terdiri dari 2 *hidden layer*, *input layer*, dan *output layer*. Algoritma *Backpropagation* memiliki 2 stages pelatihan (*training*) yaitu *forward stage* dan *backward stage*.

*Forward stage* berfungsi untuk meneruskan data-data sampel atau sinyal ( $x_1, x_2, x_3...$ ) dari input ke lapisan-lapisan selanjutnya untuk mendapatkan respon (output) dengan nilai berat dan ambang batas tertentu, *forward stage* pada *backpropagation* ditunjukkan pada persamaan 2 dengan,  $z$  adalah *weighted sum*,  $W$  adalah *weight*,  $b$  adalah bias dan  $\sigma$  adalah *activation function*, serta  $j$  dan  $l$  adalah neuron dan lapisan. Tahap selanjutnya, yaitu *backward stage* yang menentukan nilai berat dan ambang batas pada setiap neuron sehingga menghasilkan output yang diinginkan, tahap *backward stage* ditunjukkan pada Persamaan 3 dengan  $J$  adalah *loss function*.

$$z_j^{(l)} = \sum_i w_{ij}^{(l)} a_i^{(l-1)} + b_j^l$$

$$a_j^{(l)} = \sigma(z_j^{(l)}) \tag{2}$$

$$\delta_j^l = \frac{\partial J}{\partial z_j^{(l)}} \tag{3}$$



Gambar 2 Arsitektur Feed Forward Backpropagation Neural Network

**2.3. Seasonal-Trend Decomposition using LOESS (STL)**

STL Decomposition adalah salah satu jenis dekomposisi yang dapat membagi data menjadi 3 komponen yaitu komponen tren, seasonal (musiman) dan residual [12]. STL Decomposition merupakan salah satu bentuk additive decomposition, yaitu penjumlahan antara komponen tren, seasonal dan residual. Komponen tren merupakan perubahan nilai yang konsisten dalam jangka waktu tertentu. Komponen seasonal adalah perubahan atau variasi data secara periodik. Komponen residual adalah residu data yang tidak termasuk dalam komponen lainnya.

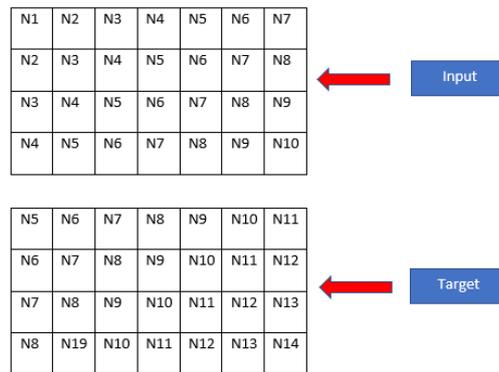
Persamaan STL decomposition seperti pada Persamaan 4.  $Y_t$  adalah nilai sebenarnya dari periode  $t$ ,  $S_t$  adalah komponen seasonal pada periode  $t$ ,  $T_t$  adalah komponen tren dari periode  $t$  dan  $E_t$  adalah komponen residual dari periode  $t$ . Penggunaan STL Decomposition dapat membuat subsekuen data menjadi lebih teratur dan mudah diprediksi [13].

$$Y_t = S_t + T_t + E_t \text{ dengan } t = 1 \text{ sampai } t = N \tag{4}$$

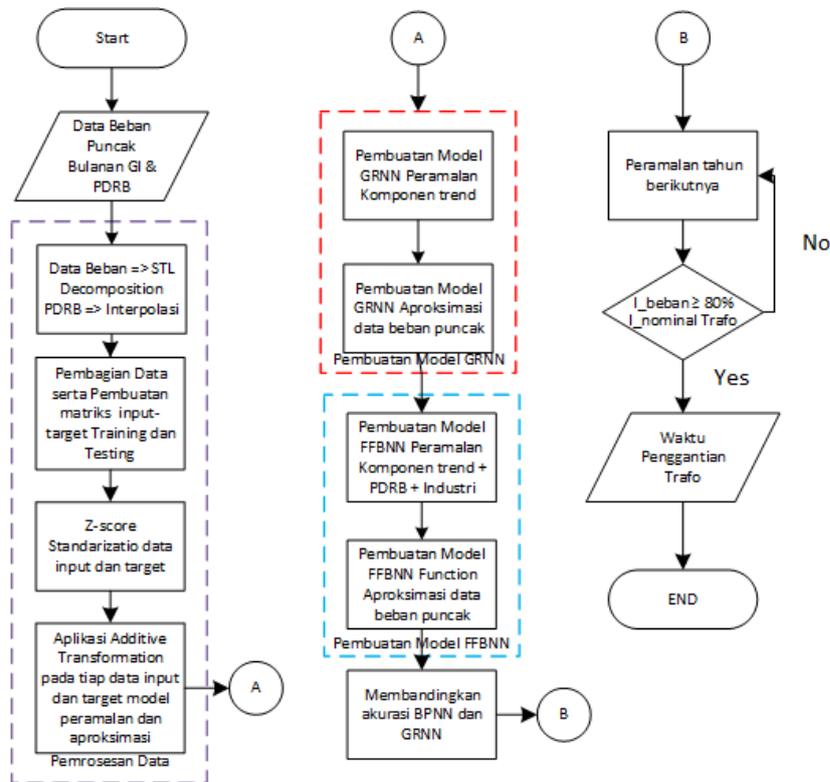
### 3. Metode Penelitian

#### 3.1. Alur Penelitian

Secara umum metode yang digunakan pada penelitian ini adalah menggunakan 2 tahap dengan 2 model yang berbeda, yaitu model peramalan untuk melakukan peramalan komponen tren dari data beban puncak bulanan transformator 3 dan 4 serta PDRB dan PDRB sektor industri. Jumlah masukan pada masing-masing model peramalan adalah 12 masukan yang merepresentasikan 12 bulan data, dengan target, yaitu 12 selanjutnya. Kemudian masukan selanjutnya adalah data dengan *lag value* yaitu 1 sehingga data hanya bergeser 1 dibandingkan masukan sebelumnya. Ilustrasi matriks data masukan dan target ditunjukkan pada Gambar 3.



Gambar 3 Ilustrasi Matriks Data Masukan dan Target

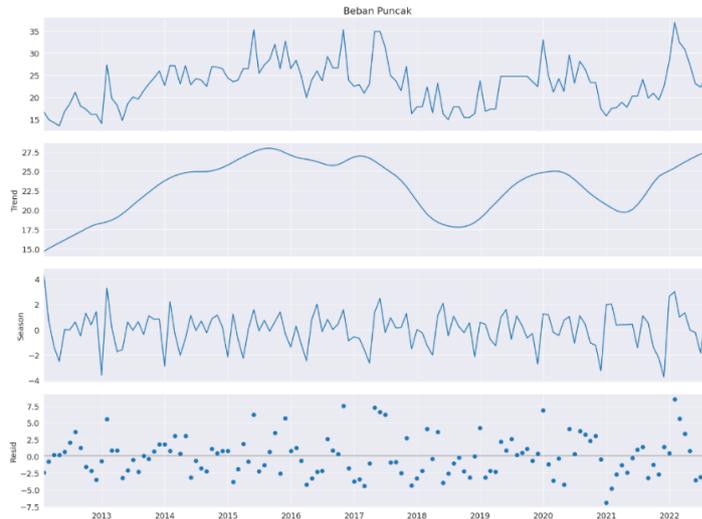


Gambar 4 Ilustrasi Diagram Alur Penelitian

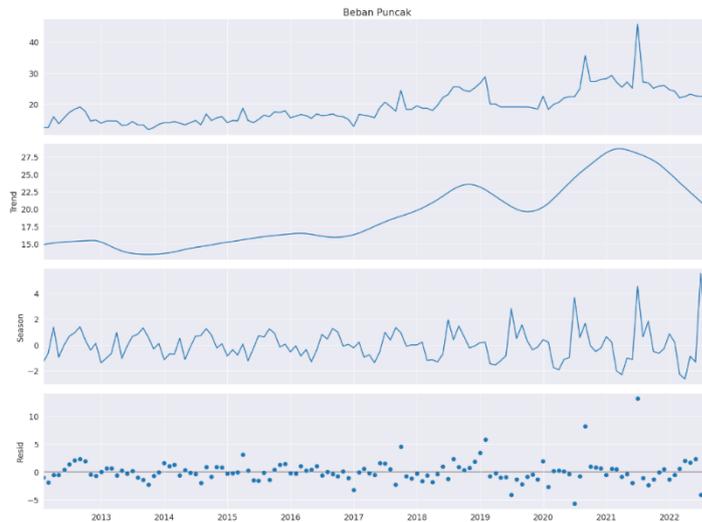
Tahap selanjutnya adalah menggunakan model aproksimasi untuk menggabungkan hasil prediksi model peramalan komponen tren pada tiap transformator serta menggabungkannya dengan hasil prediksi dari model peralaman PDRB dan PDRB sektor industri, dengan data target, yaitu data beban puncak bulanan transformator. Sehingga didapatkan hasil prediksi beban puncak bulanan tiap transformator. Data yang digunakan untuk pelatihan adalah 70% dari total rentang data sedangkan 30% digunakan untuk tahap uji model yang telah dibuat. Ilustrasi mengenai alur penelitian yang dilaksanakan pada penelitian ini ditunjukkan pada Gambar 4.

### 3.2. Praproses Data Input

Penelitian ini dilakukan menggunakan data beban puncak bulanan transformator distribusi 3 dan 4 di Gardu Induk Bangil dari bulan Mei 2012 – Desember 2022, total jumlah data yaitu 128 data untuk masing-masing transformator. Langkah pertama yaitu data puncak bulanan transformator 3 dan 4 di-dekomposisi menggunakan STL Decomposition dengan asumsi data diambil dengan rentang waktu yang sama. Hasil dekomposisi ditunjukkan pada Gambar 5 dan 6.

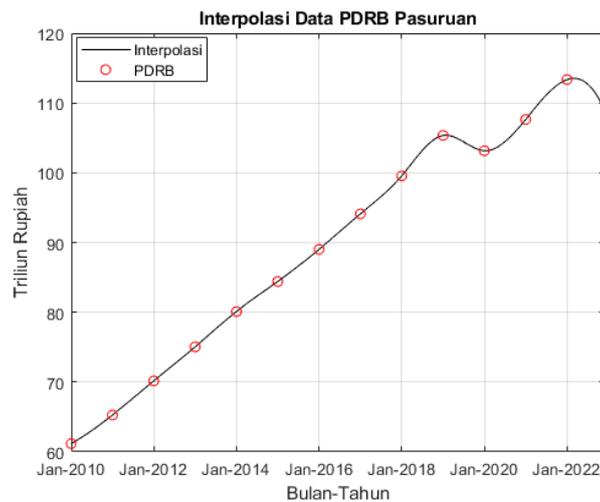


Gambar 5 Data Beban Puncak Bulanan Transformator 3 serta Hasil Dekomposisinya

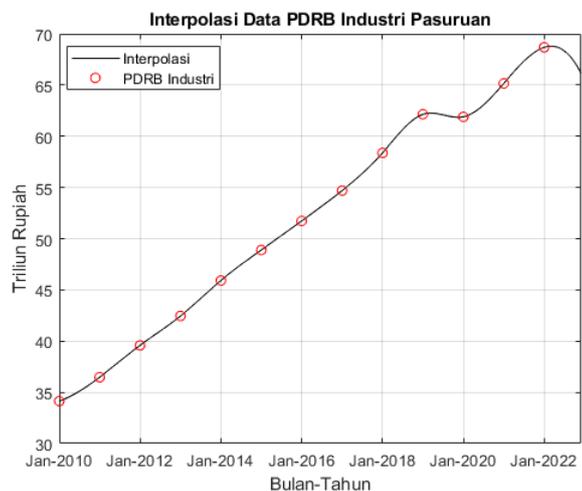


Gambar 6 Data Beban Puncak Bulanan Transformator 4 serta Hasil Dekomposisinya

Data PDRB dan PDRB sektor Industri yang digunakan adalah PDRB atas dasar harga konstan (ADHK) menurut lapangan usaha. Pemilihan PDRB ADHK karena nilai PDRB dinilai tanpa penyesuaian dengan inflasi, sehingga dapat menunjukkan pertumbuhan PDRB tiap tahunnya [14]. Data PDRB hanya tersedia dalam bentuk data tahunan. Maka agar data bisa digunakan untuk peramalan, harus mengkondisikan agar data menjadi data bulanan [15]. Metode yang digunakan adalah interpolasi dengan metode cubic spline interpolation, yaitu dilakukan aproksimasi dengan persamaan kubik. Interpolasi dilakukan dengan asumsi data PDRB tahun tersebut adalah data pada bulan Januari. Data PDRB dan PDRB sektor industri serta hasil interpolasi ditunjukkan pada Gambar 7 dan 8.



Gambar 7 Data PDRB Kabupaten Pasuruan serta Hasil Interpolasinya



Gambar 8 Data PDRB Sektor Industri Kabupaten Pasuruan serta Hasil Interpolasinya

Tahap terakhir dari praproses data masukan, yaitu menggunakan standarisasi dan *additive transformation* terhadap matriks data masukan dan target. Standarisasi dilakukan menggunakan metode z-score standardization agar rentang data masukan memiliki rentang yang sama. Kemudian additive transformation dilakukan dengan mengurangi nilai vektor masukan dan target dengan nilai rata-rata dari vector masukan. Metode ini digunakan untuk mengatasi masalah di metode GRNN yang tidak bisa digunakan untuk memprediksi data yang berupa tren [9].

### 3.3. Seleksi Fitur Data Masukan untuk Model

Seleksi fitur dilakukan menggunakan uji korelasi pearson terhadap data hasil interpolasi PDRB dan PDRB sektor industri dengan data beban puncak bulanan transformator 3 dan 4. Nilai koefisien yang digunakan untuk batas dianggap korelasi yang kuat adalah 0,7 [16]. Hasil uji korelasi ditunjukkan pada Tabel 1

Tabel 1 Hasil Uji Korelasi Pearson

Variabel	Beban Puncak Transformator 3	Beban Puncak Transformator 4	Interpolasi PDRB	Interpolasi Industri
Beban Puncak Transformator 3	1	-0,108	0,123	0,126
Beban Puncak Transformator 4	-0,108	1	0,723	0,730
Interpolasi PDRB	0,123	0,723	1	0,999
Interpolasi Industri	0,126	0,730	0,999	1

Hasil uji korelasi di atas menunjukkan jika PDRB dan PDRB sektor industri memiliki korelasi linier yang kuat dengan data beban puncak bulanan transformator 4 karena memiliki nilai koefisien korelasi yang  $\geq 0,7$ . Tetapi juga memiliki korelasi linear yang rendah dengan transformator 3. Sehingga pada transformator 4 menggunakan data PDRB dan PDRB sektor industri untuk masukan model aproksimasi.

## 4. Hasil dan Pembahasan

### 4.1. Pembuatan Model Peramalan

Pembuatan model peramalan dilakukan untuk transformator 3 dan 4 serta PDRB dan PDRB sektor industri. Model peramalan dibuat menggunakan 2 metode yang berbeda yaitu FFBNN dan GRNN. Pemilihan *hyperparameter* untuk kedua metode dilakukan secara *trial* dan *error* untuk semua kombinasi nilai pada masing-masing parameter. Data yang digunakan untuk uji yaitu 30% dari total data yaitu bulan Januari 2020- Desember 2022.

Metode untuk menganalisis tingkat akurasi model menggunakan Mean Absolute Percentage Error (MAPE) dan Mean Absolute Error (MAE). Hasil keluaran dari MAPE berupa persentase eror sehingga mempermudah dalam mengintepretasikannya [17]. Sedangkan keluaran dari MAE berupa nilai eror absolut sehingga dapat mempermudah intepretasi dari MAPE. Persamaan untuk MAPE seperti pada persamaan 5, sedangkan persamaan MAE ditunjukkan pada Persamaan 6, dengan  $y_t$  adalah nilai data beban sebenarnya,  $y_{t2}$  adalah nilai beban hasil peramalan dan T adalah jumlah data beban yang dihitung. Arsitektur model peramalan dengan metode GRNN dan FFBNN ditunjukkan pada Tabel 2, sedangkan hasil tingkat akurasi ditunjukkan pada Tabel 3.

$$MAPE = \frac{1}{T} \sum_{t=1}^T \left| \frac{y_t - y_{t2}}{y_t} \right| \times 100\% \tag{5}$$

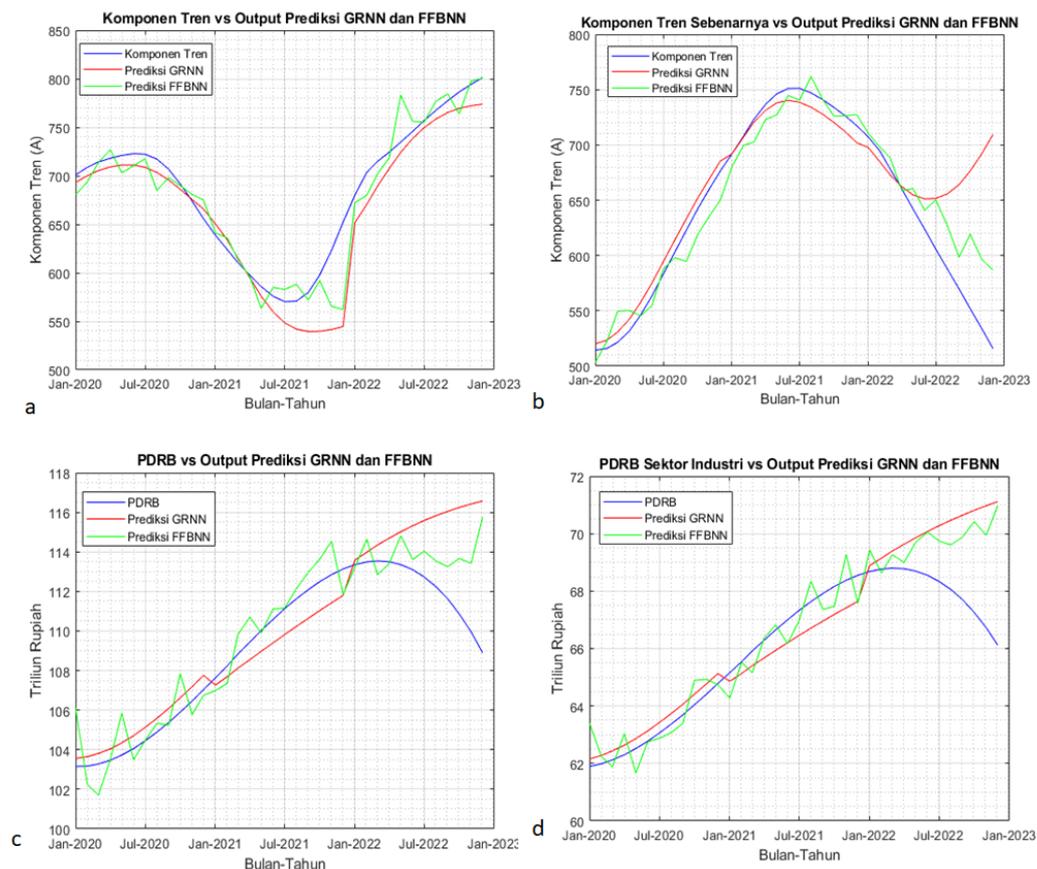
$$MAE = \frac{1}{T} \sum_{t=1}^T |y_t - y_{t2}| \tag{6}$$

Tabel 2 Arsitektur Model Peramalan dengan Metode GRNN dan FBNN

Metode	Hyperparameter	Komponen Tren Transformator 3	Komponen Tren Transformator 4	Interpolasi PDRB	Interpolasi PDRB Sektor Industri
GRNN	Pattern Layer Neuron	102	102	102	102
	Summation Layer Neuron	12	12	12	12
	Spread Parameter	0,19	0,1	0,1	0,12
FFBNN	Learning Rate	0,06	0,11	0,06	0,06
	Momentum	0,67	0,5	0,55	0,5
	Hidden Layer	1	2	1	1
	Neuron	4	12	12	13
		-	11	-	-
	Epoch	1600	1600	1500	1400

Tabel 3 Hasil Tingkat Akurasi Model Peramalan dengan GRNN dan FFBNN

Transformator	GRNN		FFBNN	
	MAPE	MAE	MAPE	MAE
Komponen Trend Transformator 3	3,035%	0.693	2.252%	0.523
Komponen Trend Transformator 4	4,743 %	0.820	3,149%	0.5678
Interpolasi PDRB	1,452%	1,601	1,098%	1,197
Interpolasi Industri	1.571%	1.051	0.921%	1.386



Gambar 9. Perbandingan Hasil Prediksi Model Peramalan GRNN dan FFBNN dengan Target pada (a) Komponen Tren Transformator 3, (b) Komponen Tren Transformator 4, (c) Interpolasi PDRB, (d) Interpolasi PDRB Sektor Industri

#### 4.2. Pembuatan Model Aproksimasi

Data bulan Mei 2012-Desember 2019 digunakan sebagai input training, sedangkan untuk input testing menggunakan hasil prediksi bulan Januari 2020-Desember 2022 dari model peramalan sedangkan data beban puncak bulanan tiap transformator sebagai target. data beban puncak sebagai target-nya. Transformator 3 hanya menggunakan hasil prediksi dari model peramalan komponen tren, sedangkan transformator 4 menggunakan hasil prediksi dari model peramalan komponen tren serta interpolasi PDRB dan PDRB sektor industri. Pemilihan hyperparameter dilakukan dengan uji coba menggunakan kombinasi dari semua nilai hyperparameter dan dipilih kombinasi hyperparameter yang memiliki nilai MAPE dan MAE terkecil. Arsitektur model aproksimasi untuk transformator 3 dan 4 yang ditunjukkan pada Tabel 4. Sedangkan perbandingan tingkat akurasi dari model tersebut ditunjukkan pada Tabel 5.

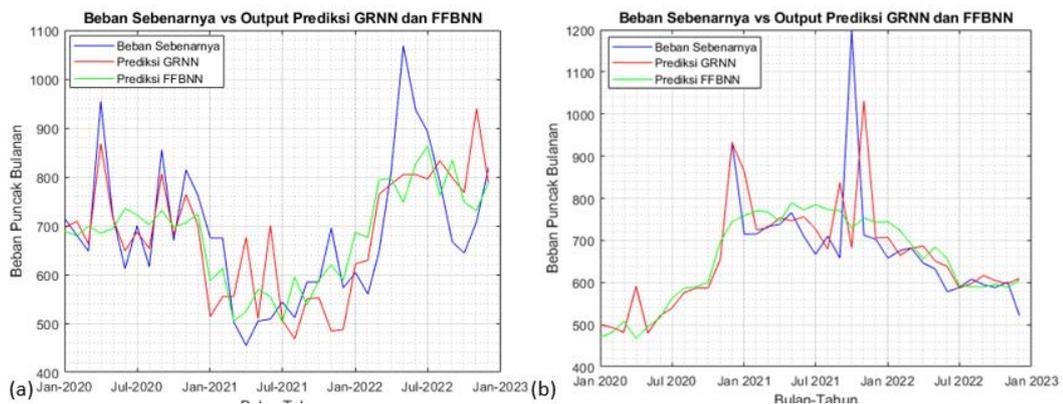
Data Tabel 5 menunjukkan jika metode FFBNN pada transformator 3 memiliki akurasi yang lebih tinggi dengan nilai MAPE dan MAE, yaitu 10,522% dan 74,204. Dibandingkan dengan metode GRNN yang memiliki nilai MAPE dan MAE yaitu 12,017% dan 80,276. Sedangkan pada transformator 4 GRNN memiliki akurasi yang lebih tinggi dengan nilai MAPE dan MAE yaitu 6,051% dan 46,557, dibandingkan dengan metode FFBNN yang memiliki nilai MAPE dan MAE yaitu 6,589% dan 47,964. Model Aproksimasi transformator 3 yang menunjukkan metode FFBNN memiliki akurasi yang lebih tinggi dari GRNN sesuai dengan penelitian sebelumnya yaitu [8], sedangkan model aproksimasi transformator 4 yang menunjukkan jika metode GRNN lebih akurat dibandingkan FFBNN sesuai dengan penelitian sebelumnya yaitu [1]. Perbedaan perbandingan hasil akurasi di penelitian ini menunjukkan jika pemilihan metode untuk peramalan beban bergantung terhadap data yang digunakan.

Tabel 4 Arsitektur Model Aproksimasi Transformator 3 dan 4 dengan metode GRNN dan FFBNN

Metode	Hyperparameter	Transformator 3	Transformator 4
GRNN	Pattern Layer Neuron	115	115
	Summation Layer Neuron	12	12
	Spread Parameter	0,1	0,14
FFBNN	Learning Rate	0,11	0,11
	Momentum	0,74	0,74
	Hidden Layer	2	2
	Neuron	5	12
		5	12
Epoch	2900	1100	

Tabel 5 Perbandingan tingkat akurasi GRNN dan FFBNN untuk Transformator 3 dan 4

Transformator	GRNN		FFBNN	
	MAPE	MAE	MAPE	MAE
Transformator 3	12,017%	2,777	10,522%	2,567
Transformator 4	6,051%	1,774	7,4572 %.	2,091



Gambar 10 Perbandingan Hasil Prediksi Model Aproksimasi GRNN dan FFBNN pada (a) Transformator 3, (b) Transformator 4

Perbedaan perbandingan nilai akurasi metode GRNN dan FFBNN pada model aproksimasi transformator 3 dan 4 diakibatkan karena perbedaan data beban puncak bulanan transformator 3 dan 4. Beban puncak bulanan transformator 3 mengalami penurunan sejak tahun 2017 sedangkan transformator 4 mengalami peningkatan hal ini karena *uprating* pada transformator 4. Selain itu, data *training* menggunakan data tahun 2012-2019 sedangkan *testing* menggunakan data tahun 2020-2022 yang merupakan tahun pandemi COVID-19. Penggunaan data sebelum pandemi COVID-19 sebagai *training* juga dapat berpengaruh terhadap akurasi dari model, karena terdapat perbedaan data saat dan sebelum pandemic, perbedaan ini juga ditemukan di beberapa kota besar lain di Indonesia[18].

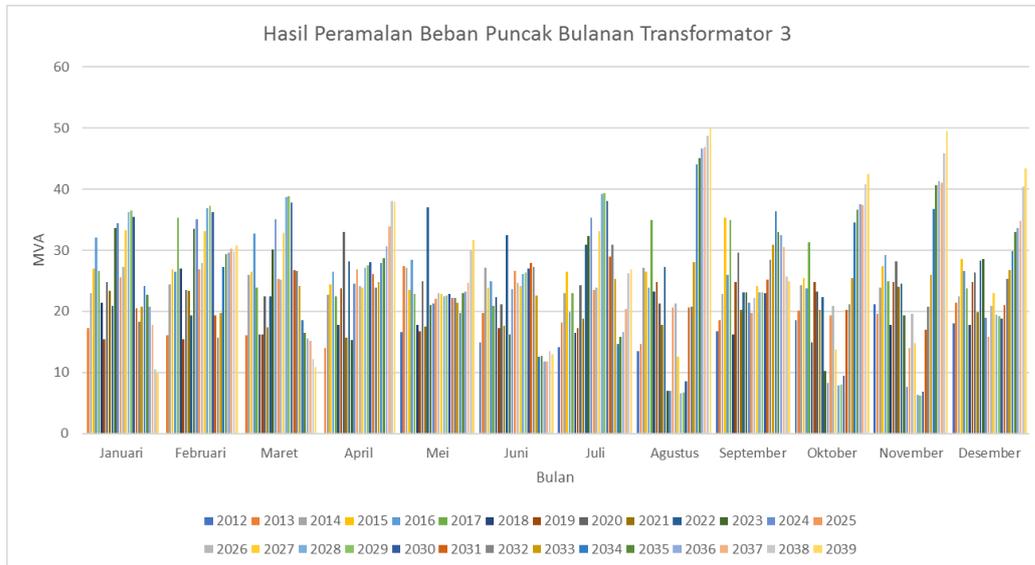
Perbedaan hasil akurasi juga bisa diakibatkan karena metode penelitian yang digunakan pada penelitian ini. Karena pada Tabel 3 perbandingan akurasi metode GRNN dan FFBNN untuk semua model peramalan menunjukkan, jika metode FFBNN memiliki akurasi yang lebih tinggi, sedangkan pada Tabel 5 perbandingan akurasi metode GRNN dan FFBNN untuk model aproksimasi memiliki hasil yang berbeda. Perbedaan tersebut dikarenakan model aproksimasi mengintegrasikan hasil peramalan dari model peramalan, sehingga eror di model aproksimasi merupakan kumulatif dari eror hasil prediksi model peramalan. Sehingga hasil pada model aproksimasi juga menunjukkan jika kemampuan aproksimasi GRNN lebih unggul dibandingkan FFBNN, hal ini sesuai dengan penelitian yang dilakukan oleh [19]. Perbedaan juga bisa diakibatkan karena penggunaan data hasil prediksi model peramalan PDRB dan PDRB sektor industri untuk model aproksimasi transformator 4, tetapi perlu penelitian lebih lanjut mengenai hal ini.

Hasil penelitian ini juga menunjukkan jika metode additive transformation yang diajukan oleh [9] dapat digunakan untuk metode FFBNN. Prediksi oleh metode aproksimasi untuk transformator 3 dan 4 pada Gambar 10 menunjukkan jika metode GRNN dan FFBNN telah mampu melakukan generalisasi terhadap data beban puncak bulanan. Sehingga pendekatan yang digunakan pada penelitian ini dapat dianggap baik dalam menghasilkan model peramalan beban yang akurat.

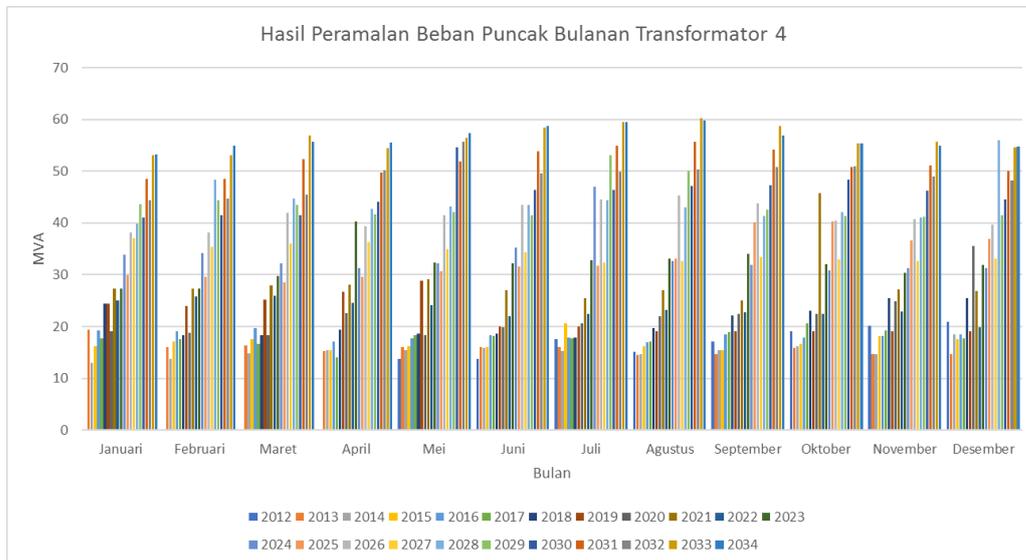
#### 4.3. Peramalan Beban Puncak Bulanan Transformator

Peramalan dilakukan dengan hasil prediksi oleh model peramalan kemudian digunakan sebagai input untuk model aproksimasi. Peramalan dilakukan untuk data bulan selanjutnya karena penelitian ini menggunakan lagged values 1 hingga hasil prediksi peramalan beban mencapai sama dengan atau melebihi pembebanan maksimal. Pembebanan maksimal adalah 70-90% dari arus nominal transformator [20], tetapi pada

penelitian ini menggunakan nilai 80% berdasarkan nilai pembebanan maksimal di Gardu Induk Bangil. Kapasitas maksimum dari transformator 3 dan 4 adalah 60MVA sehingga pembebanan maksimalnya adalah 48 MVA. Pemilihan metode peramalan beban puncak berdasarkan model aproksimasi, sehingga transformator 3 menggunakan FFBNN sedangkan transformator 4 menggunakan GRNN.



Gambar 11 Grafik Beban Puncak Bulanan Historis Tahun 2012-2022 dan Hasil Peramalan Beban Puncak Bulanan Transformator 3 Tahun 2023-2039



Gambar 12 Grafik Beban Puncak Bulanan Historis Tahun 2012-2022 dan Hasil Peramalan Beban Puncak Bulanan Transformator 4 Tahun 2023-2034

Hasil peramalan beban puncak transformator 3 ditunjukkan pada Gambar 11, pertumbuhan beban hasil peramalan tidak terlalu meningkat tiap tahunnya karena data beban historis tahun 2012-2022 juga memiliki peningkatan yang tidak terlalu besar, sehingga transformator 3 diprediksi akan mengalami *overload* yaitu pada bulan Agustus 2038 dengan nilai pembebanan 48,71 MVA. Sedangkan transformator 4 setelah uprating tahun 2017, pertumbuhan beban tahun-tahun selanjutnya cukup besar. Sehingga

mengakibatkan hasil prediksi beban puncak bulanan memiliki peningkatan yang cukup besar dan diprediksi akan mengalami *overload* pada bulan Februari 2028 dengan nilai beban 48,37 MVA.

## 5. Kesimpulan

Hasil penelitian menunjukkan hasil akurasi peramalan pada transformator 3 yang menggunakan metode FFBNN memiliki MAPE 10,522% dan GRNN memiliki MAPE 12,017%, sedangkan nilai MAE FFBNN adalah 2,567 dan nilai MAE GRNN adalah 2,777. Hasil akurasi peramalan pada transformator 4 yang menggunakan metode FFBNN memiliki MAPE 7,4572% dan GRNN memiliki nilai MAPE 6,051%, sedangkan nilai MAE FFBNN adalah 2,901. dan nilai MAE GRNN adalah 1,774.

Hasil penelitian juga menunjukkan jika Transformator 3 akan mengalami *overload* yaitu pada bulan Agustus 2038 dengan beban yaitu 48,71 MVA, sehingga uprating transformator disarankan dilakukan sebelum tanggal tersebut. Sedangkan transformator 4 akan mengalami *overload* yaitu pada bulan Februari 2028 dengan beban 48,37 MVA, sehingga uprating transformator disarankan dilakukan sebelum tanggal tersebut.

## Daftar Pustaka

- [1] W. Aribowo, S. Muslim, and I. Basuki, "Generalized Regression Neural Network for Long-Term Electricity Load Forecasting," *Proceeding - ICoSTA 2020 2020 Int. Conf. Smart Technol. Appl. Empower. Ind. IoT by Implement. Green Technol. Sustain. Dev.*, 2020, doi: 10.1109/ICoSTA48221.2020.1570611361.
- [2] T. Gonen, *Electric Power Distribution Engineering*. CRC Press, 2015.
- [3] L. Wen, K. Zhou, S. Yang, and L. Li, "Compression of smart meter big data: A survey," *Renewable and Sustainable Energy Reviews*, vol. 91. Elsevier Ltd, pp. 59–69, Aug. 01, 2018. doi: 10.1016/j.rser.2018.03.088.
- [4] S. Khatoon, Ibraheem, A. K. Singh, and Priti, "Effects of various factors on electric load forecasting: An overview," *Proc. 6th IEEE Power India Int. Conf. PIICON 2014*, 2014, doi: 10.1109/34084POWERI.2014.7117763.
- [5] M. Mustapha, M. Wazir Mustofa, S. Abd Khalid, I. Abubakar, and H. Shareef, "Classification of Electricity Load Forecasting Based on the Factors Influencing the Load Consumption and Methods Used: An-Overview," in *Conference: 2015 IEEE Conference on Energy Conversion (CENCON)*, Johor Bahru, pp. 442–447, 2015.
- [6] L. Han, Y. Peng, Y. Li, B. Yong, Q. Zhou, and L. Shu, "Enhanced deep networks for short-term and medium-term load forecasting," *IEEE Access*, vol. 7, pp. 4045–4055, 2019, doi: 10.1109/ACCESS.2018.2888978.
- [7] N. Rizki, Y. Rahmawati, and D. Prihanto, "Studi Estimasi Kapasitas Pembebanan Transformator Berdasarkan Produk Domestik Regional Bruto (Pdrb) Menggunakan Metode Regresi Linier Di Gardu Induk Buduran Kabupaten Sidoarjo," no. 1, pp. 191–200, 2019, doi: 10.5614/sniko.2018.22.
- [8] N. Kholis, I. Agung, and W. Aribowo, "Peramalan Beban Puncak Menggunakan Metode Feed Forward Backpropagation dan Generalized Regression Neural Network," *J. Tek. Elektro*, vol. 10, no. 01, pp. 109–118, 2021.

- [9] F. Martínez, F. Charte, M. P. Frías, and A. M. Martínez-Rodríguez, "Strategies for time series forecasting with generalized regression neural networks," *Neurocomputing*, vol. 491, pp. 509–521, 2022, doi: 10.1016/j.neucom.2021.12.028.
- [10] H. B. Celikoglu, "Application of radial basis function and generalized regression neural networks in non-linear utility function specification for travel mode choice modelling," *Math. Comput. Model.*, vol. 44, no. 7–8, pp. 640–658, 2006, doi: 10.1016/j.mcm.2006.02.002.
- [11] J. N. da Silva, D. H. Spatti, R. A. Flauzino, L. H. B. Liboni, and S. F. dos Reis Alves, *Artificial Neural Networks a practice course*, vol. 50, no. 2. São Carlos: Springer International Publishing, 2017. doi: 10.1254/fpj.50.2\_161.
- [12] N. Mega Prastanti, "Peramalan Harga Emas yang Dipengaruhi oleh Harga Minyak, Nilai Tukar Mata Uang, dan Indeks Standard & Poor Menggunakan Metode Generalized Regression Neural Network," Surabaya: Insitut Teknologi Surabaya, 2015.
- [13] M. Fan, Y. Hu, X. Zhang, H. Yin, Q. Yang, and L. Fan, "Short-term Load Forecasting for Distribution Network Using Decomposition with Ensemble prediction," *Proc. - 2019 Chinese Autom. Congr. CAC 2019*, pp. 152–157, 2019, doi: 10.1109/CAC48633.2019.8997169.
- [14] Badan Pusat Statistik Kabupaten Pasuruan, "Badan Pusat Statistik Kabupaten Pasuruan." Accessed: Dec. 24, 2023. [Online]. Available: <https://pasuruankab.bps.go.id/indicator/52/31/5/-seri-2010-pdrb-kabupaten-pasuruan-atas-dasar-harga-konstan-2010-menurut-lapangan-usaha.html>
- [15] J. Cho, Y. Yoon, Y. Son, H. Kim, H. Ryu, and G. Jang, "A Study on Load Forecasting of Distribution Line Based on Ensemble Learning for Mid-to Long-Term Distribution Planning," *Energies*, vol. 15, no. 9, 2022, doi: 10.3390/en15092987.
- [16] B. Jin *et al.*, "Hybrid LSTM–BPNN-to-BPNN Model Considering Multi-Source Information for Forecasting Medium- and Long-Term Electricity Peak Load," *Energies*, vol. 15, no. 20, 2022, doi: 10.3390/en15207584.
- [17] L. Qiuyu *et al.*, "Short-term Load Forecasting Based on Load Decomposition and Numerical Weather Forecast," in *2017 IEEE Conference on Energy Internet and Energy System Integration (EI2)*, Beijing, China: IEEE, pp. 4–8, 2017, doi: 10.1109/EI2.2017.8245603.
- [18] U. Surahman, D. Hartono, E. Setyowati, and A. Jurizat, "Investigation on household energy consumption of urban residential buildings in major cities of Indonesia during COVID-19 pandemic," *Energy Build.*, vol. 261, p. 111956, 2022, doi: 10.1016/j.enbuild.2022.111956.
- [19] S. Ding, X. H. Chang, and Q. H. Wu, "A study on approximation performances of general regression neural network," *Appl. Mech. Mater.*, vol. 441, pp. 713–716, 2014, doi: 10.4028/www.scientific.net/AMM.441.713.
- [20] PLN, "Rencana Usaha Penyediaan Tenaga Listrik (RUPTL) PT PLN (Persero) 2021-2030," 2021.