

Model Sistem Deteksi Kondisi Abnormal pada Konsumsi Energi Listrik di Jaringan Distribusi 1 Phase Menggunakan ANFIS

Jimmy Lukita^{1*}, Sri Ratna Sulistiyanti², F.X Arinto setyawan³, Helmy Fitriawan

Universitas Lampung; Jl. Prof. Dr. Ir. Sumantri Brojonegoro, No. 1 Bandar Lampung 35141 Indonesia;
telp +62 721 701609 . Fax +62 721 702767

Received: 27-08-2025
Accepted: 02-09-2025

Keywords:

ANFIS;
Konsumsi Listrik;
Deteksi Anomali;
Pra-pemrosesan Data

Correspondent Email:

jimmylukita1@gmail.com

Abstrak. Adaptive Neuro- Duzzy Inference System (ANFIS) terbukti mampu mengklasifikasikan pola konsumsi energi listrik dengan akurasi rata-rata 66,64% dan tingkat kesalahan 33,36%. Variasi presisi terlihat pada setiap label, dimana label 1 dan 4 memiliki nilai rendah, sementara label 2,3,dan 5 menunjukkan performa lebih baik. Presisi tertinggi mencapai 94,28% pada label 5 menandakan kemampuan ANFIS dalam mengenali pola konsumsi tertentu dengan lebih tepat. Keandalan model diperkuat melalui evaluasi menggunakan RMSE, MAE dan MBE tersebut menunjukkan kecenderungan underestimasi dalam skala yang sangat kecil. Selain itu, penerapan normalisasi data memberikan dampak positif terhadap performa model, dengan perbedaan signifikan dibandingkan data mentah, yaitu selis RMSE sebesar 0,5022 dan MAE sebesar 0,3595. Temuan ini menekankan bahwa pemilihan fungsi keanggotaan yang tepat serta normalisasi data berperan penting dalam meningkatkan efektivitas ANFIS untuk deteksi anomali konsumsi listrik.

Abstract. Adaptive Neuro-Fuzzy Inference System (ANFIS) demonstrates the ability to classify electricity consumption patterns with an average accuracy of 66.64% and an error rate of 33.36%. Precision varies across labels, where labels 1 and 4 show relatively low values, while labels 2, 3, and 5 achieve better performance. The highest precision of 94.28% is recorded for label 5, highlighting ANFIS's capability to accurately identify specific consumption patterns. The model's reliability is further validated through RMSE, MAE, and MBE evaluation. The best results are obtained using the generalized bell (gbell) membership function, yielding RMSE of 0.1634, MAE of 0.1197, and MBE of -0.00035. The MBE value indicates a very small and almost negligible underestimation tendency. Moreover, data normalization significantly enhances model performance, as shown by the substantial difference compared to raw data, with RMSE reduced by 0.5022 and MAE by 0.3595. These findings emphasize that both the selection of an appropriate membership function and data normalization play a crucial role in strengthening ANFIS's effectiveness for anomaly detection in electricity consumption.

1. PENDAHULUAN

Pelaku pencurian listrik umumnya bertujuan untuk menggunakan energi tanpa dikenakan biaya oleh penyedia listrik [1] atau membayar tagihan yang nilainya lebih kecil daripada jumlah energi yang sebenarnya digunakan [2]. Mendeteksi pencurian ini biasanya dilakukan setelah adanya laporan dari masyarakat atau berdasarkan data penggunaan listrik konsumen, hal inilah perlunya solusi untuk mempercepat pemeriksaan data agar cepat menemukan kondisi abnormal pada catatan penggunaan listrik pada masyarakat. Pendekatan yang digunakan untuk mendeteksi kondisi abnormal ini dapat dilakukan dengan cara mendeteksi konsumsi daya yang terukur dengan kondisi saat konsumsi daya normal [3].

Ada tiga kategori metode yang dapat digunakan antara lain : metode deteksi berbasis perangkat keras, gabungan perangkat keras dan data dan metode berbasis data. Metode berbasis perangkat keras yang menggunakan sensor arus untuk membaca silisih arus dengan ambang batas 0,2 Ampere [4]. Metode berbasis *machine learning* dengan model uji menggunakan data serangan simulasi [5] dan penggabungan fitur CNN dengan teknik *gradient boosting XGBoost* [6]. Logika fuzzy memiliki keunggulan dalam memodelkan pengetahuan manusia melalui aturan kualitatif, sedangkan ANN unggul karena tidak memerlukan pemodelan matematis dalam pengenalan pola dan dapat bekerja dengan data historis untuk melakukan prediksi. Dengan menggabungkan kedua metode ini, ANFIS menjadi alat yang lebih efektif untuk prediksi, menghasilkan tingkat kesalahan yang lebih rendah dibandingkan ANN [7].

Dalam Studi [8] model ANFIS digunakan untuk melakukan pengklasifikasian kanker payudara dan memberikan hasil yang akurat hal ini membuktikan bahwa ANFIS cocok untuk digunakan sebagai moden sistem untuk pengklasifikasian. Berdasarkan latar belakang di atas maka penulis tertarik melakukan penelitian penggunaan metode ANFIS dengan penambahan perlakuan pra-pemrosesan pada data masukan berupa normalisasi, dengan tujuan bagaimana merancang model sistem pendeteksi kondisi abnormal pada konsumsi energi listrik dan jenis

berdasarkan hasil output ANFIS dan seberapa besar akurasi model sistem untuk mendeteksi jenis kondisi konsumsi energi listrik.

2. TINJAUAN PUSTAKA

2.1 Alat Pengukuran dan Pembatas (APP)

Berfungsi untuk mengukur serta membatasi daya listrik yang dikonsumsi. Pengukuran dilakukan untuk menentukan jumlah energi listrik yang telah digunakan dalam periode tertentu, sedangkan pembatasan daya diterapkan agar konsumsi daya pelanggan tidak melebihi kapasitas yang disediakan oleh PLN [9].


2.2. Jenis Pelanggaran

Menurut Peraturan Direksi PT. PLN (Persero) No 088-Z.P/Dir/2016 Tentang Penertiban Pemakaian Tenaga Listrik, Jenis Dan Golongan Pelanggaran Pemakaian Tenaga Listrik Sebagai Berikut:

1. Pelanggaran Golongan I (PI) merupakan pelanggaran yang mempengaruhi batas daya tetapi tidak mempengaruhi pengukuran energi;
2. Pelanggaran Golongan II (PII) merupakan pelanggaran yang mempengaruhi pengukuran energi tetapi tidak mempengaruhi batas daya;
3. Pelanggaran Golongan III (PIII) merupakan pelanggaran yang mempengaruhi batas daya dan mempengaruhi pengukuran energi;
4. Pelanggaran Golongan IV (PIV) merupakan pelanggaran yang dilakukan oleh Bukan Pelanggan yang menggunakan tenaga listrik tanpa alas dan hak yang sah.

2.3. Skenario Pencurian Listrik

Untuk tujuan penelitian ini dilakukan 3 skenario dasar pencurian listrik yang dianggap cukup akurat [10]. Skenario dasar pencurian listrik dengan dapat dilihat pada Gambar 1.



Gambar 1. Pola Konsumsi Listrik

Gambar 1 Menunjukkan ada 3 pola pencurian listrik, (a) *Overload* merupakan kondisi konsumsi melebihi batas diatas konsumsi listrik normal. (b) *Partial Thief* adalah upaya untuk menekan biaya tagihan listrik namun menginginkan penggunaan daya yang tinggi. (c) *Periodic Thief* adalah tingkah laku konsumen dalam melakukan tindakan ilegal pada waktu tertentu, tindakan ilegal yang dilakukan bisa berupa *Overload*, *Partial Thief* atau keduanya.

2.4. K-Fold Cross Validation

Cross-validation merupakan suatu teknik statistik yang digunakan untuk memilih model yang lebih optimal dalam memprediksi kesalahan uji pada model prediktif [11]. Dalam penelitian yang dilakukan, Caon et al. menyatakan bahwa *k-Fold Cross Validation* adalah teknik yang paling efektif yang dapat diterapkan pada berbagai kasus dan mendukung pemilihan metode untuk iterasi adaptasi berikutnya [12]. Salah satu keunggulan dari *K-Fold Cross Validation* adalah kemampuannya untuk memanfaatkan seluruh data, baik untuk pelatihan maupun pengujian, sehingga lebih efisien dan dapat mengurangi bias dalam penilaian model, terutama saat bekerja dengan dataset yang terbatas [13].

2.5. Logika Fuzzy

Logika *fuzzy* adalah suatu cara yang tepat untuk memetakan suatu ruang *input* kedalam suatu ruang *output*, mempunyai nilai berkelanjutan. *Fuzzy* dinyatakan dalam derajat dari suatu keanggotaan dan derajat dari kebenaran, oleh sebab itu sesuatu dapat dikatakan sebagian benar dan sebagian salah pada waktu yang sama [14]. Pada penelitian ini bentuk kurva yang akan digunakan adalah

kurva lonceng dengan menggunakan Persamaan


$$\mu(x) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}} \tag{1}$$

Fungsi keanggotaan GBELLMF (*Generalized Bell Membership Function*) memiliki bentuk kurva menyerupai lonceng (*Bell-Shaped Curve*). Karakteristik utama kurva ini adalah nilai keanggotaannya yang tinggi di sekitar titik pusat (*Center*) dan menurun secara simetris ke kedua sisi seiring menjauhnya nilai input dari pusat tersebut. Bentuk ini dikontrol oleh tiga parameter utama, yaitu a (lebar kurva), b (kemiringan atau tingkat kelandaian sisi kurva), dan c (titik pusat kurva).

2.6. Adaptive Neuro Fuzzy Inference (ANFIS)

ANFIS merupakan integrasi antara mekanisme *Fuzzy Inference System* dengan arsitektur jaringan saraf tiruan. Sistem inferensi *Fuzzy* yang diterapkan adalah model *Takagi-Sugeno-Kang* (TSK) orde satu, dipilih karena keunggulannya dalam hal kesederhanaan dan efisiensi komputasi. Metode ini pertama kali diperkenalkan pada tahun 1985 dan terus dikembangkan lebih lanjut pada awal tahun 1990-an[7].

ANFIS mampu membangun pemetaan antara input dan output berdasarkan kecerdasan manusia dengan menerapkan aturan *Fuzzy IF-THEN* serta fungsi keanggotaan (*Membership Function*) yang relevan. Struktur dasar ANFIS tersusun atas lima lapisan utama yang saling terhubung dapat dilihat di Gambar 2.



Gambar 2. Struktur ANFIS

2.7. Normalisasi Data

Secara umum Normalisasi data adalah proses transformasi skala nilai data ke dalam rentang tertentu misalnya [0, 1] tanpa mengubah hubungan relatif antar data. Persamaan untuk melakukan normalisasi data ditunjukkan dalam Persamaan 2.

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (2)$$

Keterangan:

- x' = Nilai setelah normalisasi
- X = Nilai sebelum normalisasi
- Min(x) = Nilai Minimum
- Max(X) = Nilai Maksimum

2.8. Performance of Forecasting Model

Evaluasi model diperlukan untuk mengetahui seberapa jauh dan layak model sistem yang dibuat untuk melakukan pengklasifikasian kondisi abnormal data konsumsi energi listrik untuk mendeteksi apakah terdapat tindakan pelanggaran yang dilakukan pelanggan. Pada penelitian ini dilakukan evaluasi dengan menggunakan metode *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), *The Mean Bias Error* (MBE) dan untuk melihat nilai akurasi yang dihasilkan ANFIS menggunakan *confusion matrix* yang kemudian akan dihitung nilai akurasi, presisi dan eror.

RMSE adalah metode standar untuk memperkirakan rata-rata besar kesalahan dalam sebuah model. Fungsi ini paling umum digunakan untuk mengukur selisih antara nilai prediksi dan nilai aktual, karena mencerminkan tingkat perbedaan antara keduanya [15]. Untuk permasalahan RMSE dapat dilihat pada Persamaan 3.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (3)$$

Dimana \hat{y}_i adalah nilai prediksi, y_i adalah nilai aktual, dan N adalah jumlah titik prediksi atau jumlah sampel.

MAE merepresentasikan tingkat rata-rata kesalahan absolut. Nilai ini menggambarkan rata-rata selisih antara nilai aktual dan nilai prediksi. seperti yang ditunjukkan dalam Persamaan 4.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (4)$$

MAE tidak rentan terhadap outlier dan dapat lebih mencerminkan status sebenarnya dari kesalahan yang diprediksi [16].

MBE merupakan nilai kesalahan bias rata-rata prediksi. Ini digunakan untuk menentukan apakah nilai prediksi diremehkan <0 atau dilebih-lebihkan >0 [17]. seperti yang ditunjukkan dalam Persamaan 5.

$$MBE = \frac{1}{N} \sum_{i=1}^N y_i - \hat{y}_i \quad (5)$$

2.9. Confusion Matrix

Confusion Matrix sebuah tabel yang berisi hasil klasifikasi dari hasil pelatihan yang sudah dilakukan, matrix ini berisi pengelompokan data yang sudah lama digunakan untuk evaluasi model ilmiah seperti computer vision [18]. Elemen yang digunakan dalam tabel evaluasi ini terdiri klasifikasi TP, TN, FP, dan FN. Tabel 1 menunjukkan bentuk *Confusion Matrix*

Tabel 1 Confusion Matrix

		Kelas Prediksi	
		Positif	Negatif
Kelas Sebenarnya	Positif	TP	FP
	Negatif	FN	TN

Keterangan :

- TP (*True Positif*) dan TN (*True Negatif*) = Banyak data yang benar diprediksi
- FP (*False Positif*) dan FN (*False Negatif*) = Banyak data yang salah diprediksi

Untuk perhitungan nilai akurasi, presisi dan eror dapat menggunakan Persamaan 6, Persamaan 7 dan Persamaan 8.

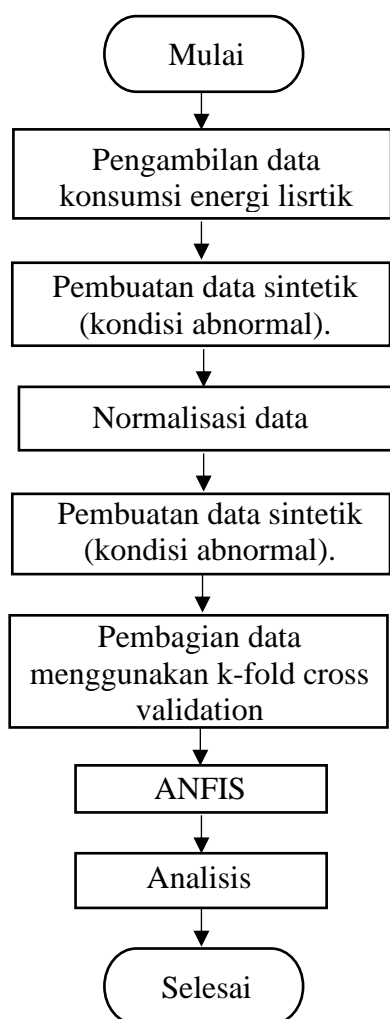
$$Akurasi = \frac{TP+FP}{TP+TN+FP+FN} \times 100\% \quad (6)$$

$$Presisi = \frac{TP}{TP+FP} \times 100\% \quad (7)$$

$$Error = \frac{FN+FP}{TP+TN+FP+FN} \times 100\% \quad (8)$$

3. METODE PENELITIAN

Data konsumsi daya yang digunakan dalam penelitian ini merupakan data historis hasil pembacaan dari Alat Pembatas dan Pengukur (APP). Pengumpulan data dilakukan setiap satu jam (pukul 07:00–18:00 WIB) dalam satu hari, selama dua belas hari berturut-turut. Data tersebut berasal dari APP milik rumah pribadi pada 03-03-2025 sampai 14-03-2025. Tahapan penelitian dalam proposal ini dapat dilihat pada Gambar 3.



Gambar 3. Tahap-tahap penelitian

Metode pengujian dilakukan untuk mengetahui setiap komponen bekerja dengan baik atau tidak, dan sesuai dengan kapasitas pada sistem yang akan dirancang. Pengujian dilakukan secara bertahap mulai dari training data dan pengujian sistem deteksi tindakan ilegal pada APP.

3.1. Pengujian Sistem ANFIS


Pengujian ini dirancang untuk membandingkan hasil prediksi menggunakan MATLAB dengan data aktual yang diperoleh dari pembacaan konsumsi daya listrik (Watt) melalui Alat Pembatas dan Pengukur (APP). Proses pengujian ini dilakukan untuk memperoleh nilai epoch yang optimal dan jumlah membership function yang cocok untuk data yang dilakukan pelatihan, sehingga dari hasil pengujian ini dapat dilakukan evaluasi akurasi prediksi ANFIS yang diimplementasikan pada MATLAB, dengan memeriksa nilai eror yang dihasilkan.

3.2. Pengujian Sistem Tindakan Ilegal

Pengujian sistem tindakan ilegal ANFIS, dilakukan untuk mengevaluasi terhadap kinerja sistem *Adaptive Neuro-Fuzzy Inference System* (ANFIS). Data yang digunakan dalam pengujian ini terdiri dari data konsumsi listrik dalam kondisi normal serta data sintetik yang telah direkayasa untuk menggambarkan kondisi anomali. Data sintetik tersebut mencakup Label 2 (*Sedikit Overload*) dan Label 3 (*Overload*) yang dihasilkan melalui peningkatan nilai konsumsi sebesar 50% dan 80%, serta Label 4 (*Sedikit Partial*) dan Label 5 (*Partial*) yang diperoleh dari penurunan nilai sebesar 50% dan 80%. Keempat label tersebut merepresentasikan berbagai skenario manipulasi beban listrik yang mencerminkan tindakan ilegal.

4. HASIL DAN PEMBAHASAN

Tahapan awal yang dilakukan adalah pengumpulan data, data berasal dari konsumsi listrik pribadi yang dicatat setiap jam mulai dari pukul 07:00-18:00 WIB yang dilakukan selama 12 hari. Data terbagi menjadi 5 label, data normal, data sedikit *overload*, data *overload*, data sedikit *partial* dan data *partial* dengan total seluruhnya ada 720 data. Untuk gambar grafik konsumsi listrik berdasarkan label dapat dilihat pada Gambar 4.




Gambar 4. Data Konsumsi Listrik Berdasarkan Label

Gambar 4 berisi data yang digunakan untuk label 2 (sedikit *overload*), label 3 (*overload*), label 4 (sedikit *partial*), dan label 5 (*partial*) merupakan data sintetis yang disusun sebagai skenario kondisi tidak normal. Proses pembentukan data sintesis ini didasari pada data normal sebagai data acuan dengan skenario peningkatan nilai data diambang batas normal pada label 2 dan label 3 sebesar 50% dan 80% sebaliknya penurunan nilai data dibawah batas normal pada label 4 dan label 5 sebesar 50% dan 80%.


4.1. Implementasi Sistem ANFIS

Pada penelitian ini input yang digunakan berupa waktu pengambilan data dan hasil jumlah konsumsi energi listrik yang terpakai sedangkan untuk outputnya terdiri dari 5 klasifikasi. Fungsi keanggotaan waktu dapat dilihat pada Gambar 5 yang memiliki fungsi keanggotaan berupa pagi,siang dan sore.



Gambar 5. Diagram fungsi keanggotaan input 1

Fungsi keanggotaan konsumsi listrik dapat dilihat pada Gambar 6 yang memiliki fungsi keanggotaan berupa rendah, sangat rendah, normal, tinggi, sangat tinggi.



Gambar 6. Diagram fungsi keanggotaan input 2

Berdasarkan nilai dari fungsi keanggotaan di atas maka didapatkan nilai awal parameter a, b, dan c yang akan digunakan dalam proses ANFIS. Untuk lebih jelasnya dapat dilihat pada Tabel 2.

Tabel 2. Nilai a,b dan c pada fungsi keanggotaan input 1 dan input 2

	Himpunan fuzzy	a	b	c
Input 1 (waktu)	Pagi	0.3227	2.004	0.0922
	Siang	0.2943	1.991	0.4724
	Sore	0.3267	2.003	0.9057
Input 2 (Konsumsi Listrik)	Sangat Rendah	0.1483	2.001	0.05999
	Rendah	0.1534	2.002	0.208
	Sedang	0.1143	2	0.4793
	Tinggi	0.1218	2	0.7172
	Sangat Tinggi	0.1973	1.987	0.9323

4.2. Evaluasi Kinerja Model

Pada penelitian ini data yang akan diuji pada sistem ANFIS ada 2 jenis yaitu: data tanpa proses normalisasi dan data sudah dilakukan normalisasi. Pada pengujian ini kurva yang akan digunakan adalah *trapmf*, *trimf* dan *gbellmf*. Untuk perbandingan hasil evaluasi dapat dilihat pada Tabel 3.

Tabel 3 Hasil Perbandingan Evaluasi Nilai Rata-Rata RMSE,MAE dan MBE

Jenis Data	Fungsi Keanggotaan (Grafik Kurva)	RMSE
Tanpa Normalisasi	<i>Trimf</i>	0.7236
	<i>Trapmf</i>	0.7412
	<i>Gbellmf</i>	0.6656
Dengan Normalisasi	<i>Trimf</i>	0.1808
	<i>Trapmf</i>	0.1777
	<i>Gbellmf</i>	0.1634
Jenis Data	Fungsi Keanggotaan (Grafik Kurva)	MAE
Tanpa Normalisasi	<i>Trimf</i>	0.5388
	<i>Trapmf</i>	0.5502
	<i>Gbellmf</i>	0.4791
Dengan Normalisasi	<i>Trimf</i>	0.1337
	<i>Trapmf</i>	0.1342
	<i>Gbellmf</i>	0.1196
Jenis Data	Fungsi Keanggotaan (Grafik Kurva)	MBE
Tanpa Normalisasi	<i>Trimf</i>	0.00267
	<i>Trapmf</i>	-0.00353
	<i>Gbellmf</i>	-0.09061
Dengan Normalisasi	<i>Trimf</i>	-0.00008
	<i>Trapmf</i>	-0.00030
	<i>Gbellmf</i>	-0.00035

Tabel 3 menunjukkan nilai hasil evaluasi terkecil ada di fungsi keanggotaan *GBELLMF* dengan data yang sudah dilakukan normalisasi. Hasil pengukuran pada fungsi keanggotaan *gbellmf* dengan data yang sudah dilakukan normalisasi menunjukkan untuk nilai RMSE-nya bernilai **0.16343840**, MAE bernilai **0.11968652** dan MBE positif dengan nilai **-0.00035222** yang berarti data cenderung mengalami *underestimasi*. Berdasarkan ke tiga parameter tersebut dapat dikatakan bahwa sistem ANFIS memiliki tingkat cukup bagus dan cocok menfeteksi kondisi abnormal konsumsi listrik

4.3. Evaluasi Akurasi, Presisi dan Error

Untuk mengukur kehandalan sistem secara mendalam tidak hanya dilihat dari nilai RMSE, MAE dan MBE, tetapi dengan melakukan perhitungan nilai akurasi, presisi dan nilai error. Hal ini memiliki tujuan agar dapat menilai kemampuan model dari sisi keakuratan dan ketepatan model dalam pengklasifikasi hasil secara benar. Seluruh perhitungan nilai akurasi, presisi dan error pada setiap fold dapat dilihat pada Tabel 4. Berdasarkan Tabel 4 rata-

rata akurasi yang diperoleh 66,64% dengan eror 33,36%, yang menandakan bahwa meskipun ANFIS mampu melakukan klasifikasi, hasilnya masih belum optimal. Persisi pada label 1 memiliki nilai terendah yaitu 38,02%, yang menunjukkan bahwa masih banyak prediksi positif yang salah (false positive) pada kelas tersebut.

Tabel 4. Nilai Rata-Rata Akurasi, dan Error Seluruh Fold

	Akurasi(%)	Error(%)
Fold 1	75	25
Fold 2	68	32
Fold 3	69,4	30,6
Fold 4	68	32
Fold 5	61,1	38,9
Fold 6	59,72	40,28
Fold 7	58,33	41,67
Fold 8	62,5	37,5
Fold 9	75	25
Fold 10	69,44	30,56
Rata-Rata	66,64	33,36

Tabel 5. Nilai Presisi Seluruh Fold

	Presisi (%)				
	Label 1	Label 2	Label 3	Label 4	Label 5
Fold 1	70,5	82,3	90	35	100
Fold 2	35	87,5	73,3	33,33	100
Fold 3	27,27	87,5	71,42	61,1	90
Fold 4	50	57,14	83,33	58,82	93,3
Fold 5	23	78,94	56,25	56,25	100
Fold 6	25	86,67	69,23	38,46	80
Fold 7	21,42	64,28	73,33	40	92,85
Fold 8	35,71	79,62	84,61	35,29	86,67
Fold 9	46,15	100	84,21	37,27	100
Fold 10	46,15	84,61	82,35	37,27	100
Avg	38,02	80,89	76,80	43,279	94,28

Selanjutnya, presisi meningkat signifikan pada label 2 dengan nilai 80,89%, serta label 3 dengan nilai 76,80%, yang menandakan bahwa model lebih mampu mengidentifikasi label ini dengan benar. Namun, pada label 4 terjadi penurunan presisi 43,27%, sehingga kinerja model dalam membedakan label ini masih tergolong rendah. Sementara itu label 5 menunjukkan presisi tertinggi yaitu 94,28%, menandakan bahwa model memiliki

kemampuan yang sangat baik dalam mengenali kelas ini dengan kesalahan yang sangat sedikit.

5. KESIMPULAN

- a. Berdasarkan hasil penelitian, sistem ANFIS mampu melakukan klasifikasi kondisi konsumsi energi listrik dengan rata-rata akurasi sebesar 66,64% dan tingkat eror 33,36%. Nilai presisi pada tiap label menunjukkan variasi, dimana label 1 dan 4 memiliki meiliki presisi rendah, sedangkan label 2,3 dan 5 menunjukkan performa yang lebih baik dengan presisi tertinggi pada label 5 sebesar 94,28% hal ini mendakan bahwa model ANFIS ini mampu mengidentifikasi label ini.
- b. Hasil evaluasi kehandalan ANFIS dalam memprediksi nilai aktual konsumsi listrik ditunjukkan melalui perhitungan RMSE, MAE dan MBE. Pengujian menunjukkan bahwa penggunaan gbell membership function menghasilkan performa terbaik dengan nilai RMSE sebesar 0,16343840, MAE 0,11968652, dan MBE - 0,00035222, yang mengindikasikan adanya kecenderungan underestimasi meskipun dalam skala sangat kecil. Selain itu, proses normalisasi data terbukti berpengaruh positif terhadap kinerja model, terlihat dari adanya perbedaan signifikan antara data yang tidak dinormalisasi dan data yang dinormalisasi, yakni selisih RMSE sebesar 0,50223293 dan MAE sebesar 0,35948832.

DAFTAR PUSTAKA

- [1] M. Anwar, N. Javaid, A. Khalid, M. Imran, and M. Shoaib, "Electricity theft detection using pipeline in machine learning," in *Proc. Int. Wireless Commun. Mobile Comput. (IWCMC)*, Jun. 2020, pp. 2138–2142.
- [2] Z. Zheng, Y. Yang, X. Niu, H.-N. Dai, and Y. Zhou, "Wide and deep convolutional neural networks for electricity-theft detection to secure smart grids," *IEEE Trans. Ind. Informat.*, vol. 14, no. 4, pp. 1606–1615, Apr. 2018.
- [3] A. Fiki, R. N. Pratiwi, and A. Wachid, "Strategi PT. Perusahaan Listrik Negara dalam pemenuhan tenaga listrik dan peningkatan pelayanan pada masyarakat di Pulau Giligenting Kabupaten Sumenep (studi pada pembangkit listrik tenaga disel Subrayon Giligenting)," *J. Adm. Publik (JAP)*, vol. 1, no. 6, pp. 1229–1238, 2013.
- [4] J. Astronomo, M. D. Dayrit, C. Edjic, and E. R. T. Regidor, "Development of electricity theft detector with GSM module and alarm system," in *Proc. IEEE 12th Int. Conf. Humanoid, Nanotechnol., Inf. Technol., Commun. Control, Environ., Manage. (HNICEM)*, Dec. 2020, pp. 1–5.
- [5] O. A. Abraham *et al.*, "Electricity theft detection for smart homes: Harnessing the power of machine learning with real and synthetic attacks," *IEEE Access*, vol. 12, pp. 26023–26045, 2024.
- [6] S. O. Madbouly and H. A. Guesmi, "Efficient electricity theft detection using hybrid CNN-XGBoost model," *J. Comput. Biomed. Informatics*, 2024.
- [7] J.-S. R. Jang, "ANFIS: Adaptive-network-based fuzzy inference system," *IEEE Trans. Syst., Man, Cybern.*, vol. 23, no. 3, pp. 665–685, 1993.
- [8] N. Nurhayati, O. D. Oky, *et al.*, "Peningkatan citra termogram untuk klasifikasi kanker payudara berbasis Adaptive Neuro Fuzzy Inference System (ANFIS)," *Electrician: J. Rekayasa Teknol. Elektro*, vol. 4, no. 1, pp. 33–37, 2010.
- [9] C. Rawan, Y. P. Hikmat, and H. Purnama, "Rancang bangun modul pengukuran energi listrik tidak langsung menggunakan kWh dan kvarh meter," in *Proc. Industrial Research Workshop and National Seminar (IRWNS)*, vol. 14, no. 1, pp. 116–122, Aug. 2023.
- [10] H. Henderi, T. Wahyuningsih, and E. Rahwanto, "Comparison of Min-Max normalization and Z-score normalization in the K-nearest neighbor (kNN) algorithm to test the accuracy of types of breast cancer," *Int. J. Informatics Inf. Syst.*, vol. 4, no. 1, pp. 13–20, 2021.
- [11] S. Ribaric and I. Fratric, "Experimental evaluation of matching-score normalization techniques on different multimodal biometric systems," in *Proc. Mediterr. Electrotech. Conf. (MELECON)*, 2006, pp. 498–501, doi: 10.1109/melcon.2006.1653147.
- [12] P. Tamilarasi and U. Rani, "Diagnosis of crime rate against women using k-Fold cross validation through machine learning algorithms," in *Proc. IEEE 4th Int. Conf. Comput. Methodologies Commun. (ICCMC)*, 2020, pp. 1034–1038.
- [13] D. R. S. Caon, A. Amehraye, J. Razik, G. Chollet, R. V. Andreao, and C. Mokbel, "Experiments on acoustic model supervised

- adaptation and evaluation by k-Fold cross validation technique,” *IEEE Int. J.*, pp. 1–4, 2010.
- [14] F. Susilo, *Himpunan dan logika kabur serta aplikasi*. Yogyakarta, Indonesia: Graha Ilmu, 2006.
- [15] P. Du *et al.*, “A novel hybrid model for short-term wind power forecasting,” *Appl. Soft Comput.*, vol. 80, pp. 93–106, 2019.
- [16] H. Zheng and Y. Wu, “A XGBoost model with weather similarity analysis and feature engineering for short-term wind power forecasting,” *Appl. Sci.*, vol. 9, no. 15, p. 3019, 2019.
- [17] A. T. Peiris, J. Jayasinghe, and U. Rathnayake, “Forecasting wind power generation using artificial neural network: ‘Pawan Danawi’—A case study from Sri Lanka,” *J. Electr. Comput. Eng.*, vol. 2021, no. 1, p. 5577547, 2021.
- [18] S. Li and W. Deng, “Blended emotion in-the-wild: Multi-label facial expression recognition using crowdsourced annotations and deep locality feature learning,” *Int. J. Comput. Vis.*, vol. 127, no. 6, pp. 884–906, 2019.