

Implementasi Metode Adaptive Neuro-Fuzzy Inference System Terhadap Prediksi Tingkat Kemiskinan Di Kabupaten/Kota Jawa Timur

Tsalsya Ni'matul Aulia, Evawati Alisah*, and Erna Herawati

Program Studi Matematika, Fakultas Sains dan Teknologi, UIN Maulana Malik Ibrahim Malang, Indonesia

Article History

Received 20 November 2025

Revised 15 Februari 2026

Accepted 21 April 2026

Published 30 April 2026



Copyright © 2026 by Authors, Published by JRMM Group. This is an open access article under the CC BY-SA License.



Abstract. This study aims to evaluate the effectiveness of the Adaptive Neuro-Fuzzy Inference System (ANFIS) in predicting poverty levels in the regencies/municipalities of East Java Province. ANFIS is a hybrid method that combines fuzzy logic and artificial neural networks, enabling it to model complex socio-economic data with uncertainty. The input variables used in this study are the open unemployment rate, population growth rate, and school participation rate for ages 16–18, while the target variable is the poverty level. The data were obtained from Statistics Indonesia (BPS) and cover the years 2022, 2023, and 2024. Modeling was conducted using a time-based split approach, in which 2022 data were used as training input to predict the 2023 poverty level, and 2023 data were used as testing input to predict the 2024 poverty level. The training process employed a hybrid algorithm combining Least Squares Estimation (LSE) and backpropagation. Model performance was evaluated using Mean Squared Error (MSE). The results show that ANFIS produces highly accurate poverty-level predictions, with a testing MSE of 3.98×10^{-24} . Therefore, ANFIS can be considered effective for analyzing and predicting socio-economic phenomena at the regional level.

Keywords: ANFIS, Poverty Prediction, Time-Based Split, MSE, East Java.

Abstrak. Penelitian ini bertujuan untuk menganalisis dan mengevaluasi efektivitas metode *Adaptive Neuro-Fuzzy Inference System* (ANFIS) dalam memprediksi tingkat kemiskinan di kabupaten/kota Provinsi Jawa Timur. ANFIS merupakan metode hibrida yang menggabungkan logika fuzzy dan jaringan saraf tiruan, sehingga mampu memodelkan data sosial ekonomi yang kompleks dan mengandung ketidakpastian. Variabel input yang digunakan terdiri atas tingkat pengangguran terbuka, laju pertumbuhan penduduk, dan angka partisipasi sekolah usia 16–18 tahun, sedangkan variabel target berupa tingkat kemiskinan. Data yang digunakan bersumber dari Badan Pusat Statistik (BPS) dan mencakup tahun 2022, 2023, dan 2024. Pemodelan dilakukan dengan pendekatan *time-based split*, yaitu data tahun 2022 digunakan sebagai input pelatihan untuk memprediksi tingkat kemiskinan tahun 2023, sedangkan data tahun 2023 digunakan sebagai input pengujian untuk memprediksi tingkat kemiskinan tahun 2024. Proses pelatihan menggunakan algoritma hibrida yang menggabungkan *Least Squares Estimation* (LSE) dan *backpropagation*. Kinerja model dievaluasi menggunakan *Mean Squared Error* (MSE). Hasil penelitian menunjukkan bahwa ANFIS mampu menghasilkan prediksi tingkat kemiskinan dengan akurasi yang sangat tinggi, yaitu nilai MSE pengujian sebesar 3.98×10^{-24} . Oleh karena itu, metode ANFIS dinilai efektif dalam menganalisis dan memprediksi fenomena sosial ekonomi di tingkat daerah.

Kata kunci: ANFIS, Prediksi Kemiskinan, Time-Based Split, MSE, Jawa Timur.

1. Pendahuluan

Perkembangan teknologi dan meningkatnya kebutuhan analisis prediktif dalam bidang sosial ekonomi mendorong pemanfaatan metode komputasi cerdas yang mampu mengolah data kompleks dan mengandung ketidakpastian. Salah satu pendekatan yang banyak digunakan adalah *Adaptive Neuro-Fuzzy Inference System* (ANFIS), yaitu metode hibrida yang menggabungkan logika fuzzy dan jaringan saraf tiruan. Integrasi kedua pendekatan tersebut menghasilkan sistem inferensi adaptif yang mampu belajar dari data historis serta memodelkan hubungan nonlinier antarvariabel sosial ekonomi [1].

Logika fuzzy dan jaringan saraf tiruan memiliki karakteristik yang saling melengkapi. Logika fuzzy unggul dalam merepresentasikan ketidakpastian melalui derajat keanggotaan, sedangkan jaringan saraf tiruan memiliki kemampuan dalam pembelajaran dan optimasi parameter. Kombinasi keduanya memungkinkan ANFIS menyesuaikan parameter fungsi keanggotaan secara otomatis sehingga model prediksi yang di-

hasilkan bersifat adaptif, efisien, dan akurat, termasuk ketika diterapkan pada dataset berukuran terbatas.

Kemiskinan masih menjadi salah satu permasalahan struktural di Indonesia, termasuk di Provinsi Jawa Timur. Berdasarkan Badan Pusat Statistik (BPS) [2], kemiskinan mencerminkan ketidakmampuan individu atau rumah tangga dalam memenuhi kebutuhan dasar, seperti pangan, tempat tinggal, pendidikan, dan kesehatan. Studi lain menunjukkan bahwa tingkat kemiskinan di Jawa Timur cenderung lebih tinggi di wilayah pedesaan akibat keterbatasan akses terhadap layanan publik dan peluang ekonomi [3]. Kompleksitas faktor yang memengaruhi kemiskinan menunjukkan perlunya pendekatan analitik yang mampu menangkap pola hubungan nonlinier antarvariabel sosial ekonomi.

Berbagai penelitian terdahulu telah menunjukkan efektivitas ANFIS dalam pemodelan prediktif. Aldin dan Sözer [4] melaporkan bahwa ANFIS mencapai akurasi tinggi dalam prediksi suhu. Matsniya *et al.* [5] membuktikan kemampuan ANFIS dalam memprediksi produksi tembakau dengan tingkat kesalahan yang rendah. Wisudawaty dan Djatna

*Corresponding author. E-mail: evawatialisah@mat.uin-malang.ac.id

[6] menerapkan ANFIS untuk prediksi penjualan keripik kacangpring dan memperoleh akurasi sebesar 99,902% dengan MAPE 3,96%. Rohana *et al.* [7] juga menunjukkan bahwa Hybrid ANFIS mengungguli metode *Backpropagation* dalam memprediksi pertumbuhan penduduk. Temuan-temuan tersebut mengindikasikan bahwa ANFIS memiliki potensi untuk diterapkan dalam analisis fenomena sosial ekonomi, termasuk kemiskinan.

Penelitian ini menggunakan ANFIS untuk memprediksi tingkat kemiskinan di kabupaten/kota Provinsi Jawa Timur. Variabel input yang digunakan adalah Tingkat Pengangguran Terbuka (TPT), laju pertumbuhan penduduk, dan Angka Partisipasi Sekolah (APS) usia 16–18 tahun, sedangkan variabel target adalah persentase tingkat kemiskinan. Pendekatan *time-based split* diterapkan agar proses pelatihan dan pengujian mengikuti urutan waktu, sehingga model hanya menggunakan informasi historis dalam menghasilkan prediksi.

Berdasarkan latar belakang tersebut, penelitian ini berupaya menjawab pertanyaan utama mengenai kinerja metode ANFIS dalam memprediksi tingkat kemiskinan di kabupaten/kota Provinsi Jawa Timur. Kontribusi penelitian ini terletak pada implementasi ANFIS untuk data sosial ekonomi tingkat daerah, pembuktian empiris mengenai hubungan antara TPT, pertumbuhan penduduk, APS, dan tingkat kemiskinan, serta penguatan potensi ANFIS sebagai alat analisis prediktif berbasis data dalam perencanaan pembangunan daerah.

Struktur artikel ini disusun sebagai berikut. Bagian 2 menjelaskan data, tahapan pra-proses, struktur ANFIS, serta prosedur evaluasi model. Bagian 3 menyajikan hasil pemodelan dan pembahasan. Bagian 4 memuat kesimpulan dan rekomendasi penelitian lanjutan.

2. Metode

Penelitian ini menggunakan pendekatan deskriptif kuantitatif yang didukung oleh studi literatur. Data yang digunakan merupakan data sekunder dari Badan Pusat Statistik (BPS) Provinsi Jawa Timur. Data tersebut meliputi tingkat kemiskinan, Tingkat Pengangguran Terbuka (TPT), laju pertumbuhan penduduk, dan Angka Partisipasi Sekolah (APS) usia 16–18 tahun pada 38 kabupaten/kota di Provinsi Jawa Timur selama periode 2022–2024.

Metode yang diterapkan adalah *Adaptive Neuro-Fuzzy Inference System* (ANFIS). ANFIS merupakan metode hibrida yang menggabungkan kemampuan logika fuzzy dalam menangani ketidakpastian dengan kemampuan jaringan saraf tiruan dalam melakukan pembelajaran dari data. ANFIS dikembangkan oleh Jang [8] berdasarkan konsep logika fuzzy yang diperkenalkan oleh Zadeh. Metode ini mampu memodelkan hubungan nonlinier antara variabel input dan output sehingga sesuai untuk permasalahan prediksi yang kompleks dan dinamis, termasuk analisis sosial ekonomi.

Secara umum, proses pemodelan dalam penelitian ini terdiri atas pra-proses data, pelatihan model, dan pengujian model. Tahap pra-proses mencakup pemilihan variabel, pembagian data berdasarkan waktu, serta normalisasi data. Tahap pelatihan dilakukan melalui alur maju menggunakan LSE dan alur mundur menggunakan *backpropagation*. Tahap pengujian dilakukan dengan menerapkan parameter hasil pelatihan pada

data uji dan mengevaluasi hasilnya menggunakan MSE.

2.1. Pra-Proses Data

Pra-proses data dilakukan untuk memastikan bahwa data siap digunakan dalam pemodelan ANFIS. Variasi rasio pembagian data latih dan data uji dapat memengaruhi akurasi model, terutama pada dataset yang relatif kecil, sehingga strategi pembagian data perlu ditentukan secara hati-hati [9]. Salah satu pendekatan yang umum digunakan adalah *holdout validation*, yaitu sebagian data historis digunakan untuk pelatihan dan sebagian lainnya digunakan untuk pengujian. Cerqueira dkk. [10] menekankan bahwa strategi berbasis waktu lebih sesuai untuk data nonstasioner karena mampu menjaga konsistensi temporal dan mencegah *data leakage* yang dapat muncul pada *random cross-validation*.

Tingkat kemiskinan dalam penelitian ini didefinisikan sebagai persentase penduduk yang hidup di bawah garis kemiskinan. Variabel ini digunakan sebagai variabel target karena mampu menggambarkan kondisi kesejahteraan suatu wilayah. Pemilihan variabel input dilakukan dengan mempertimbangkan faktor sosial ekonomi yang relevan terhadap dinamika kemiskinan. Lestari dkk. [11] menegaskan bahwa analisis kemiskinan di Provinsi Jawa Timur perlu mempertimbangkan variabel sosial ekonomi yang berpengaruh terhadap variasi tingkat kemiskinan.

Berdasarkan pertimbangan tersebut, penelitian ini menggunakan tiga variabel input, yaitu TPT (X_1), laju pertumbuhan penduduk (X_2), dan APS usia 16–18 tahun (X_3). Variabel target (Y) adalah tingkat kemiskinan. Pembagian data dilakukan menggunakan pendekatan *time-based split* dengan rasio 50:50. Data tahun 2022 digunakan sebagai input pelatihan dengan target tingkat kemiskinan tahun 2023, sedangkan data tahun 2023 digunakan sebagai input pengujian dengan target tingkat kemiskinan tahun 2024. Strategi ini diterapkan untuk mendukung skema *one-step-ahead forecasting*, menjaga validitas temporal pemodelan, dan menyesuaikan kebutuhan ANFIS dalam mempelajari parameter premis serta parameter konsekuen dari data historis [12, 13].

2.2. Normalisasi Data

Sebelum proses fuzzifikasi dilakukan, seluruh variabel input dan output dinormalisasi ke dalam rentang $[0, 1]$ menggunakan metode *min-max normalization*. Normalisasi diperlukan agar proses pembelajaran lebih stabil, konvergensi lebih cepat, dan variabel dengan skala besar tidak mendominasi proses perhitungan fungsi keanggotaan maupun pembaruan parameter. Rumus normalisasi yang digunakan ditunjukkan pada Persamaan (1).

$$X_{\text{norm}} = \frac{X - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}}. \quad (1)$$

Pada Persamaan (1), X menyatakan nilai data asli, X_{min} menyatakan nilai minimum, X_{max} menyatakan nilai maksimum, dan X_{norm} menyatakan nilai data hasil normalisasi.

2.3. Arsitektur ANFIS

Model ANFIS dalam penelitian ini dibangun dengan struktur lima lapisan. Setiap lapisan memiliki fungsi khusus, mulai

dari pembentukan derajat keanggotaan, perhitungan kekuatan aturan, normalisasi bobot aturan, pembentukan fungsi konsekuen, hingga agregasi output akhir. Arsitektur ini memungkinkan sistem fuzzy Sugeno mempelajari pola data melalui kombinasi parameter premis dan parameter konsekuen.

2.3.1. Lapisan Pertama: Fungsi Keanggotaan

Lapisan pertama berfungsi mengubah nilai input hasil normalisasi menjadi derajat keanggotaan fuzzy. Setiap variabel input, yaitu X_1 , X_2 , dan X_3 , diklasifikasikan ke dalam tiga kategori linguistik, yaitu rendah, sedang, dan tinggi. Secara umum, keluaran lapisan pertama dinyatakan pada Persamaan (2).

$$O_{1,j}^{(k)} = \mu_{A_j^{(k)}}(X_k), \quad j = 1, 2, 3, \quad k = 1, 2, 3. \quad (2)$$

Pada Persamaan (2), $O_{1,j}^{(k)}$ menyatakan keluaran fungsi keanggotaan ke- j pada variabel input ke- k , sedangkan $\mu_{A_j^{(k)}}(X_k)$ menyatakan derajat keanggotaan nilai X_k terhadap himpunan fuzzy $A_j^{(k)}$.

Kategori linguistik sedang direpresentasikan menggunakan fungsi *generalized bell*. Bentuk fungsi tersebut ditunjukkan pada Persamaan (3).

$$\mu_A(x) = \frac{1}{1 + \left(\frac{|x-c|}{a}\right)^{2b}}. \quad (3)$$

Pada Persamaan (3), a mengontrol lebar kurva, b mengontrol kemiringan kurva, dan c menyatakan pusat kurva. Kategori linguistik rendah dan tinggi dimodelkan menggunakan fungsi sigmoid. Fungsi sigmoid naik ditunjukkan pada Persamaan (4), sedangkan fungsi sigmoid turun ditunjukkan pada Persamaan (5).

$$\mu(x) = \frac{1}{1 + e^{-a(x-c)}}. \quad (4)$$

$$\mu(x) = \frac{1}{1 + e^{a(x-c)}}. \quad (5)$$

Pada Persamaan (4) dan Persamaan (5), x menyatakan nilai input, a menyatakan parameter kecuraman kurva, dan c menyatakan titik tengah atau *threshold*. Penentuan parameter pada fungsi *generalized bell* dan sigmoid dilakukan menggunakan pendekatan statistik berdasarkan data terkecil (X_{\min}), kuartil pertama (Q_1), median (Q_2), kuartil ketiga (Q_3), dan data terbesar (X_{\max}) [14].

2.3.2. Lapisan Kedua: Kekuatan Aturan

Lapisan kedua menghitung kekuatan aktivasi atau *firing strength* dari setiap aturan fuzzy. Karena penelitian ini menggunakan tiga variabel input dan setiap variabel memiliki tiga kategori linguistik, jumlah aturan fuzzy yang terbentuk adalah 27 aturan, sebagaimana dinyatakan pada Persamaan (6).

$$R = 3^3 = 27. \quad (6)$$

Setiap aturan fuzzy dihitung dengan mengalikan derajat keanggotaan dari masing-masing variabel input. Bentuk

umum perhitungan *firing strength* ditunjukkan pada Persamaan (7).

$$O_{2,m} = \omega_m = \prod_{k=1}^3 \mu_{A_{j_k}^{(k)}}(X_k), \quad m = 1, 2, \dots, R. \quad (7)$$

Pada Persamaan (7), ω_m menyatakan kekuatan aktivasi aturan ke- m , sedangkan R menyatakan jumlah aturan fuzzy.

2.3.3. Lapisan Ketiga: Normalisasi Bobot Aturan

Lapisan ketiga menormalisasi *firing strength* setiap aturan agar diperoleh bobot relatif terhadap seluruh aturan yang aktif. Normalisasi bobot aturan dinyatakan pada Persamaan (8).

$$O_{3,m} = \bar{\omega}_m = \frac{\omega_m}{\sum_{j=1}^R \omega_j}, \quad m = 1, 2, \dots, R. \quad (8)$$

Pada Persamaan (8), $\bar{\omega}_m$ menyatakan bobot aturan ke- m yang telah dinormalisasi.

2.3.4. Lapisan Keempat: Fungsi Konsekuen

Lapisan keempat membentuk fungsi konsekuen pada setiap aturan fuzzy. Karena penelitian ini menggunakan tiga variabel input, fungsi konsekuen pada aturan ke- m untuk data ke- i dinyatakan pada Persamaan (9).

$$f_{m,i} = p_m X_{1,i} + q_m X_{2,i} + r_m X_{3,i} + s_m. \quad (9)$$

Pada Persamaan (9), p_m , q_m , r_m , dan s_m merupakan parameter konsekuen pada aturan ke- m . Keluaran lapisan keempat diperoleh dengan mengalikan bobot aturan ternormalisasi dan fungsi konsekuen, sebagaimana ditunjukkan pada Persamaan (10).

$$O_{4,m,i} = \bar{\omega}_{m,i} f_{m,i}. \quad (10)$$

Parameter konsekuen dihitung menggunakan *Least Squares Estimation* (LSE). Model linier LSE dinyatakan pada Persamaan (11).

$$y = A\theta. \quad (11)$$

Pada Persamaan (11), A menyatakan matriks regresor yang dibentuk dari input dan bobot aturan ternormalisasi, θ menyatakan vektor parameter konsekuen, dan y menyatakan vektor target. Estimasi parameter konsekuen diperoleh menggunakan Persamaan (12).

$$\theta = (A^T A)^{-1} A^T y. \quad (12)$$

2.3.5. Lapisan Kelima: Agregasi Output

Lapisan kelima menghasilkan output akhir ANFIS dengan menjumlahkan seluruh keluaran aturan fuzzy dari lapisan keempat. Bentuk agregasi output ditunjukkan pada Persamaan (13).

$$O_{5,i} = \sum_{m=1}^R \bar{\omega}_{m,i} f_{m,i}. \quad (13)$$

Pada Persamaan (13), $O_{5,i}$ menyatakan prediksi ANFIS untuk data ke- i .

2.4. Alur Mundur dan Pembaruan Parameter

Setelah alur maju menghasilkan nilai prediksi, model menghitung galat antara output prediksi dan target aktual. Galat ini kemudian dipropagasikan kembali untuk memperbaiki parameter fungsi keanggotaan. Proses ini dilakukan melalui algoritma *backpropagation* berbasis turunan MSE.

Turunan galat pada lapisan kelima dinyatakan pada Persamaan (14).

$$\varepsilon_{5,i} = \frac{\partial}{\partial O_{5,i}} \left[\frac{(y_i - O_{5,i})^2}{2} \right] = O_{5,i} - y_i. \quad (14)$$

Pada Persamaan (14), $\varepsilon_{5,i}$ menyatakan galat pada lapisan kelima untuk data ke- i , $O_{5,i}$ menyatakan output prediksi, dan y_i menyatakan target aktual.

Galat pada lapisan ketiga dihitung berdasarkan kontribusi fungsi konsekuen terhadap output akhir. Perhitungan tersebut dinyatakan pada Persamaan (15).

$$\varepsilon_{3,m,i} = \varepsilon_{5,i} f_{m,i}. \quad (15)$$

Pada Persamaan (15), $\varepsilon_{3,m,i}$ menyatakan galat bobot aturan ternormalisasi untuk aturan ke- m dan data ke- i . Galat ini kemudian dipropagasikan ke lapisan kedua. Dengan $S_i = \sum_{j=1}^R \omega_{j,i}$, galat lapisan kedua dinyatakan pada Persamaan (16).

$$\varepsilon_{2,m,i} = \varepsilon_{3,m,i} \frac{S_i - \omega_{m,i}}{S_i^2} - \sum_{k \neq m} \varepsilon_{3,k,i} \frac{\omega_{k,i}}{S_i^2}. \quad (16)$$

Pada Persamaan (16), $\varepsilon_{2,m,i}$ menyatakan galat pada *firing strength* aturan ke- m . Galat pada lapisan pertama selanjutnya dihitung dengan memperhatikan kontribusi derajat keanggotaan terhadap *firing strength*. Bentuk perhitungannya ditunjukkan pada Persamaan (17).

$$\varepsilon_{1,m,i} = \varepsilon_{2,m,i} \frac{\omega_{m,i}}{O_{1,m,i}}. \quad (17)$$

Pada Persamaan (17), $\varepsilon_{1,m,i}$ menyatakan galat yang diterima fungsi keanggotaan pada lapisan pertama. Galat ini digunakan untuk memperbaiki parameter fungsi keanggotaan. Perubahan parameter dinyatakan pada Persamaan (18).

$$\begin{aligned} \Delta a_{im} &= \eta \varepsilon_a(i, m) x_i, \\ \Delta b_{im} &= \eta \varepsilon_b(i, m) x_i, \\ \Delta c_{im} &= \eta \varepsilon_c(i, m) x_i. \end{aligned} \quad (18)$$

Pada Persamaan (18), η menyatakan laju pembelajaran, sedangkan $\varepsilon_a(i, m)$, $\varepsilon_b(i, m)$, dan $\varepsilon_c(i, m)$ menyatakan komponen galat terhadap masing-masing parameter fungsi keanggotaan. Parameter fungsi keanggotaan kemudian diperbarui menggunakan Persamaan (19).

$$\begin{aligned} a_{im}(t+1) &= a_{im}(t) + \Delta a_{im}, \\ b_{im}(t+1) &= b_{im}(t) + \Delta b_{im}, \\ c_{im}(t+1) &= c_{im}(t) + \Delta c_{im}. \end{aligned} \quad (19)$$

Pada Persamaan (19), t menyatakan indeks iterasi dalam proses pelatihan. Proses alur maju dan alur mundur dilakukan secara berulang hingga nilai galat mendekati minimum.

2.5. Pengujian dan Evaluasi Model

Setelah proses pelatihan selesai, model diuji menggunakan data uji dengan menjalankan alur maju berdasarkan parameter premis dan parameter konsekuen hasil pelatihan. Output model yang masih berada pada skala normalisasi dikembalikan ke skala asli melalui proses denormalisasi. Rumus denormalisasi ditunjukkan pada Persamaan (20).

$$X = X_{\text{norm}}(X_{\text{max}} - X_{\text{min}}) + X_{\text{min}}. \quad (20)$$

Pada Persamaan (20), X_{norm} menyatakan nilai hasil prediksi dalam skala normalisasi, sedangkan X menyatakan nilai hasil prediksi pada skala asli.

Kinerja model dievaluasi menggunakan *Mean Squared Error* (MSE). MSE dipilih karena dapat mengukur rata-rata kuadrat selisih antara nilai aktual dan nilai prediksi. Rumus MSE ditunjukkan pada Persamaan (21).

$$E = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2. \quad (21)$$

Pada Persamaan (21), n menyatakan jumlah data, y_i menyatakan nilai aktual, dan \hat{y}_i menyatakan nilai prediksi.

3. Hasil dan Pembahasan

Bagian ini menyajikan hasil pengolahan data dan analisis model ANFIS dalam memprediksi tingkat kemiskinan di kabupaten/kota Provinsi Jawa Timur. Pembahasan disusun secara berurutan mulai dari struktur data, normalisasi, pembentukan fungsi keanggotaan, perhitungan setiap lapisan ANFIS, proses pelatihan, hingga evaluasi hasil pengujian.

3.1. Struktur Data dan Pembagian Data

Data penelitian diperoleh dari laman resmi Badan Pusat Statistik (BPS) dan memuat indikator sosial ekonomi pada 38 kabupaten/kota di Provinsi Jawa Timur. Variabel yang digunakan terdiri atas tingkat kemiskinan sebagai variabel target (Y), serta tiga variabel input, yaitu Tingkat Pengangguran Terbuka (X_1), Laju Pertumbuhan Penduduk (X_2), dan Angka Partisipasi Sekolah usia 16–18 tahun (X_3).

Pendekatan *time-based split* digunakan untuk menjaga urutan temporal data. Data tahun 2022 digunakan sebagai input pelatihan dengan target tahun 2023, sedangkan data tahun 2023 digunakan sebagai input pengujian dengan target tahun 2024. Setiap kabupaten/kota direpresentasikan sebagai unit observasi ke- i , dengan $i = 1, 2, \dots, 38$. Rangkuman pembagian data pelatihan dan pengujian disajikan pada Tabel 1.

Tabel 1: Pembagian Data Pelatihan dan Pengujian

i	Data Pelatihan				Data Pengujian			
	TPT 2022	LPP 2022	APS 2022	Target 2023	TPT 2023	LPP 2023	APS 2023	Target 2024
1	3.65	0.66	78.45	13.65	1.83	0.12	79.06	13.08
2	5.51	0.90	78.18	9.53	4.66	0.39	79.36	9.11
3	5.37	0.67	84.99	10.63	4.52	0.50	83.34	10.50
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
38	8.43	0.99	80.28	8.20	3.31	4.52	3.38	3.06

Tabel 1 menunjukkan bahwa data disusun berdasarkan pasangan input dan target pada tahun berikutnya. Susunan ini memungkinkan model mempelajari hubungan antara kondisi sosial ekonomi pada tahun tertentu dan tingkat kemiskinan pada tahun setelahnya.

3.2. Normalisasi Data

Seluruh variabel input dan target dinormalisasi menggunakan Persamaan (1). Normalisasi diterapkan pada TPT, LPP, APS, dan tingkat kemiskinan agar seluruh variabel berada pada skala yang sama. Hasil normalisasi sebagian data pelatihan disajikan pada Tabel 2.

Tabel 2: Hasil Normalisasi Data

i	TPT (2022)	LPP (2022)	APS (2022)	Target (2023)
1	0.307796	0.400	0.708072	0.560434
2	0.557796	0.592	0.701547	0.337127
3	0.538978	0.408	0.866119	0.396748
⋮	⋮	⋮	⋮	⋮
38	0.950269	0.664	0.752296	0.300000

Berdasarkan Tabel 2, seluruh nilai input dan target telah berada pada rentang $[0, 1]$. Hasil ini menjadi dasar bagi proses fuzzifikasi pada lapisan pertama ANFIS.

3.3. Pelatihan Model ANFIS

Pelatihan model ANFIS dilakukan melalui alur maju dan alur mundur. Alur maju digunakan untuk menghitung output model berdasarkan fungsi keanggotaan, aturan fuzzy, bobot aturan, dan parameter konsekuen. Alur mundur digunakan untuk menghitung galat dan memperbarui parameter fungsi keanggotaan.

3.3.1. Parameter Fungsi Keanggotaan

Pada lapisan pertama, setiap variabel input diklasifikasikan ke dalam tiga kategori linguistik, yaitu rendah, sedang, dan tinggi. Kategori rendah dan tinggi dimodelkan menggunakan fungsi sigmoid pada Persamaan (4) dan Persamaan (5), sedangkan kategori sedang dimodelkan menggunakan fungsi *generalized bell* pada Persamaan (3). Parameter fungsi keanggotaan ditentukan berdasarkan kuartil data hasil normalisasi. Rangkuman parameter fungsi keanggotaan disajikan pada Tabel 3.

Tabel 3: Parameter Fungsi Keanggotaan

Fungsi	Parameter	Rumus	TPT	LPP	APS
Sigmoid	a	$\frac{1}{Q_3 - Q_1}$	3.729323	3.731343	2.831822
Sigmoid	c	Q_2	0.531586	0.44	0.701909
Gbell	a	$\frac{Q_3 - Q_1}{2}$	0.134073	0.134000	0.176565
Gbell	b	Konstan	2	2	2
Gbell	c	Q_2	0.531586	0.44	0.701909

Tabel 3 menunjukkan bahwa parameter fungsi keanggotaan untuk setiap variabel ditentukan berdasarkan karakteristik distribusi data. Parameter tersebut digunakan untuk menghitung nilai keanggotaan fuzzy pada setiap observasi. Hasil perhitungan derajat keanggotaan pada lapisan pertama disajikan pada Tabel 4.

Tabel 4: Nilai Fungsi Keanggotaan TPT, LPP, dan APS

i	TPT			LPP			APS		
	R	S	T	R	S	T	R	S	T
1	0.697	0.114	0.303	0.537	0.992	0.463	0.496	1.000	0.504
2	0.476	0.999	0.524	0.362	0.377	0.638	0.500	1.000	0.500
3	0.493	1.000	0.507	0.530	0.997	0.470	0.386	0.572	0.614
					⋮				
38	0.173	0.010	0.827	0.302	0.114	0.698	0.464	0.993	0.536

Tabel 4 memperlihatkan derajat keanggotaan setiap observasi terhadap kategori rendah (R), sedang (S), dan tinggi (T). Nilai-nilai ini digunakan sebagai input untuk menghitung kekuatan aturan pada lapisan kedua.

3.3.2. Pembentukan Aturan Fuzzy dan Lapisan Kedua

Aturan fuzzy disusun berdasarkan kombinasi penuh dari tiga variabel input. Karena setiap variabel memiliki tiga kategori linguistik, jumlah aturan fuzzy yang terbentuk adalah 27 aturan sebagaimana dinyatakan pada Persamaan (6). Rangkuman struktur aturan fuzzy disajikan pada Tabel 5.

Tabel 5: Aturan Fuzzy

Indeks Aturan	TPT	LPP	APS
W1	Rendah	Rendah	Rendah
W2	Rendah	Rendah	Sedang
W3	Rendah	Rendah	Tinggi
		⋮	
W26	Tinggi	Tinggi	Sedang
W27	Tinggi	Tinggi	Tinggi

Tabel 5 menunjukkan sebagian aturan fuzzy yang digunakan dalam model. Setiap aturan menghitung nilai *firing strength* menggunakan Persamaan (7). Hasil perhitungan lapisan kedua disajikan pada Tabel 6.

Tabel 6: Hasil Lapisan Kedua

i	W1	W2	W3	W27
1	0.185682	0.374633	0.188951	0.070644
2	0.086099	0.172110	0.086011	0.167232
3	0.100792	0.149449	0.160464	0.146385
			⋮	
38	0.024358	0.052107	0.028094	0.308829

Tabel 6 menunjukkan kekuatan aktivasi beberapa aturan fuzzy. Nilai tersebut merepresentasikan tingkat kesesuaian setiap observasi terhadap aturan fuzzy tertentu.

3.3.3. Normalisasi Bobot Aturan pada Lapisan Ketiga

Setelah *firing strength* diperoleh, lapisan ketiga menormalisasi bobot aturan menggunakan Persamaan (8). Normalisasi dilakukan agar setiap bobot aturan dapat diinterpretasikan sebagai kontribusi relatif terhadap seluruh aturan. Rangkuman hasil perhitungan lapisan ketiga disajikan pada Tabel 7.

Tabel 7 menunjukkan bahwa setiap *firing strength* telah dinormalisasi. Nilai bobot ternormalisasi ini digunakan dalam pembentukan fungsi konsekuen pada lapisan keempat.

Tabel 7: Hasil Lapisan Ketiga

i	W1	W2	W3	W27
1	0.04183	0.084397	0.042567	0.015915
2	0.015648	0.031280	0.015632	0.030393
3	0.016055	0.023805	0.025560	0.023317
		⋮		
38	0.010861	0.023233	0.012526	0.137697

3.3.4. Estimasi Parameter Konsekuen dan Lapisan Keempat

Pada lapisan keempat, setiap aturan fuzzy menghasilkan fungsi konsekuen linier sebagaimana dinyatakan pada Persamaan (9). Parameter konsekuen p_m , q_m , r_m , dan s_m diestimasi menggunakan LSE berdasarkan Persamaan (11) dan Persamaan (12). Rangkuman parameter LSE disajikan pada Tabel 8.

Tabel 8: Parameter LSE

Rule	p	q	r	s
1	-0.24523	-5.01495	3.68142	-1.63431
2	0.533779	0.712124	-0.20561	4.307695
3	0.144569	-2.36849	0.955859	3.36920
		⋮		
27	8.692915	10.03075	8.345534	5.236933

Tabel 8 memperlihatkan sebagian parameter konsekuen yang diperoleh dari proses estimasi LSE. Parameter ini digunakan untuk menghitung keluaran setiap aturan pada lapisan keempat berdasarkan Persamaan (10). Hasil perhitungan lapisan keempat disajikan pada Tabel 9.

Tabel 9: Hasil Lapisan Keempat

i	Rule 1	Rule 2	Rule 3	Rule 27
1	-0.04639	0.389176	0.133792	0.283822
2	-0.03376	0.152733	0.042492	0.664970
3	-0.01002	0.112072	0.084570	0.495330
		⋮		
38	-0.02637	0.119257	0.033232	3.640198

Tabel 9 menunjukkan keluaran beberapa aturan fuzzy setelah bobot ternormalisasi dikalikan dengan fungsi konsekuen masing-masing aturan.

3.3.5. Agregasi Output pada Lapisan Kelima

Lapisan kelima menjumlahkan seluruh output aturan fuzzy untuk memperoleh nilai prediksi akhir ANFIS. Perhitungan agregasi output dilakukan menggunakan Persamaan (13). Rangkuman hasil perhitungan lapisan kelima disajikan pada Tabel 10.

Tabel 10 menunjukkan hasil prediksi akhir dalam skala normalisasi. Nilai prediksi tersebut kemudian dibandingkan dengan target untuk menghitung galat pelatihan.

3.3.6. Perhitungan Galat pada Alur Mundur

Alur mundur dimulai dari lapisan kelima dengan menghitung selisih antara output prediksi dan target aktual menggunakan

Tabel 10: Hasil Lapisan Kelima

i	Prediksi ($O_{5,i}$)
1	0.12345
2	0.23456
3	0.34567
	⋮
38	0.56789

Persamaan (14). Hasil galat lapisan kelima disajikan pada Tabel 11.

Tabel 11: Hasil Galat Lapisan Kelima

i	Galat ($\varepsilon_{5,i}$)
1	-4.4×10^{-16}
2	-2.1×10^{-15}
3	5.55×10^{-16}
	⋮
38	3.11×10^{-15}

Tabel 11 menunjukkan bahwa galat pada lapisan keluaran berada pada orde yang sangat kecil. Galat tersebut selanjutnya dipropagasikan ke lapisan ketiga menggunakan Persamaan (15). Hasil perhitungan galat lapisan ketiga disajikan pada Tabel 12.

Tabel 12: Hasil Galat Lapisan Ketiga

i	Rule 1	Rule 2	Rule 3	Rule 27
1	4.93×10^{-16}	-2.05×10^{-15}	-1.40×10^{-15}	-7.92×10^{-15}
2	4.55×10^{-15}	-1.03×10^{-14}	-5.73×10^{-15}	-4.62×10^{-14}
3	-3.46×10^{-16}	2.61×10^{-15}	1.84×10^{-15}	1.18×10^{-14}
		⋮		
38	-7.55×10^{-15}	1.60×10^{-14}	8.25×10^{-15}	8.22×10^{-14}

Tabel 12 memperlihatkan galat yang diterima oleh bobot aturan ternormalisasi. Galat ini digunakan untuk menghitung galat lapisan kedua berdasarkan Persamaan (16). Hasil perhitungan galat lapisan kedua disajikan pada Tabel 13.

Tabel 13 menunjukkan galat pada kekuatan aturan. Galat tersebut kemudian dipropagasikan ke lapisan pertama menggunakan Persamaan (17). Rangkuman hasil galat lapisan pertama untuk aturan pertama disajikan pada Tabel 14.

Tabel 14 menunjukkan galat yang diterima oleh fungsi keanggotaan pada lapisan pertama. Nilai galat tersebut digunakan untuk memperbarui parameter fungsi keanggotaan menggunakan Persamaan (18) dan Persamaan (19).

3.3.7. Kriteria Penghentian Pelatihan

Proses pelatihan dihentikan menggunakan mekanisme *early stopping*. Kriteria yang digunakan meliputi batas maksimum 100 epoch, ambang penurunan MSE antarepoch sebesar $\Delta\text{MSE} \leq 10^{-25}$, *patience* selama tiga epoch berturut-turut, dan target error absolut sebesar $\text{MSE} \leq 10^{-25}$ sebagai indikator kualitas minimum model [15]. Penerapan kriteria tersebut bertujuan untuk mencegah *underfitting* dan *overfitting*, sekaligus menjaga efisiensi komputasi selama pelatihan [16]. Hasil iterasi pelatihan disajikan pada Tabel 15.

Tabel 13: Hasil Galat Lapisan Kedua

i	Rule 1	Rule 2	Rule 3	Rule 27
1	7.41×10^{-16}	-1.80×10^{-15}	-1.15×10^{-15}	-7.67×10^{-15}
2	5.26×10^{-15}	-9.59×10^{-15}	-5.02×10^{-15}	-4.54×10^{-14}
3	-5.67×10^{-16}	2.39×10^{-15}	1.62×10^{-15}	1.16×10^{-14}
		\vdots		
38	-7.55×10^{-15}	1.60×10^{-14}	8.25×10^{-15}	8.22×10^{-14}

Tabel 14: Hasil Galat Lapisan Kesatu

i	Rule 1		
	TPT	LPP	APS
1	4.45×10^{-17}	5.77×10^{-17}	6.26×10^{-17}
2	1.73×10^{-16}	2.28×10^{-16}	1.65×10^{-16}
3	-1.84×10^{-17}	-1.72×10^{-17}	-2.36×10^{-17}
		\vdots	
38	-4.73×10^{-16}	-2.71×10^{-16}	-1.77×10^{-16}

Berdasarkan Tabel 15, nilai MSE pada epoch ke-14 mencapai 6.36×10^{-26} . Nilai tersebut telah memenuhi target error absolut $MSE \leq 10^{-25}$. Selain itu, penurunan MSE pada beberapa epoch terakhir menunjukkan pola yang relatif stabil. Dengan demikian, meskipun batas maksimum 100 epoch belum tercapai, kriteria *early stopping* telah terpenuhi sehingga proses pelatihan dihentikan pada epoch ke-14.

3.4. Pengujian dan Evaluasi Model

Setelah proses pelatihan selesai, model diuji menggunakan data pengujian. Data pengujian tidak digunakan dalam proses pelatihan, sehingga hasilnya dapat digunakan untuk menilai kemampuan generalisasi model. Pada tahap ini, model ANFIS menjalankan alur maju menggunakan parameter hasil pelatihan dan menghasilkan prediksi dalam skala normalisasi. Hasil prediksi kemudian dikembalikan ke skala asli menggunakan Persamaan (20).

Setelah proses denormalisasi, nilai prediksi dibandingkan dengan target aktual tahun 2024. Nilai galat dihitung menggunakan MSE pada Persamaan (21). Rangkuman hasil denormalisasi, nilai aktual, dan galat prediksi disajikan pada Tabel 16.

Tabel 16 menunjukkan bahwa hasil prediksi ANFIS sangat dekat dengan nilai aktual. Nilai galat berada pada orde 10^{-13} hingga 10^{-12} , sehingga selisih antara output denormalisasi dan data aktual secara praktis sangat kecil. Hasil ini menunjukkan bahwa model ANFIS mampu menangkap pola hubungan antara variabel sosial ekonomi dan tingkat kemiskinan pada skema pengujian yang digunakan.

Nilai MSE pengujian yang diperoleh adalah 3.98×10^{-24} . Nilai tersebut menunjukkan bahwa perbedaan kuadrat rata-rata antara nilai aktual dan nilai prediksi sangat kecil. Grafik perbandingan antara target aktual dan hasil prediksi disajikan pada Gambar 1.

Gambar 1 memperlihatkan bahwa nilai prediksi hampir berimpit dengan nilai aktual. Kesesuaian tersebut menunjukkan bahwa struktur fuzzy, parameter fungsi keanggotaan, dan parameter konsekuen yang dihasilkan melalui proses pelatihan mampu merepresentasikan pola data dengan sangat baik. Dengan demikian, ANFIS dapat digunakan sebagai pendekatan prediktif untuk menganalisis tingkat kemiskinan

Tabel 15: Iterasi Proses Pelatihan

Epoch	MSE	Δ MSE	Epoch	MSE	Δ MSE
1	1.58×10^{-24}		8	1.51×10^{-25}	3.22×10^{-25}
2	7.81×10^{-25}	7.99×10^{-25}	9	5.10×10^{-25}	3.59×10^{-25}
3	8.26×10^{-25}	0.45×10^{-25}	10	2.21×10^{-25}	2.89×10^{-25}
4	3.57×10^{-25}	4.69×10^{-25}	11	4.41×10^{-25}	2.2×10^{-25}
5	1.15×10^{-24}	7.93×10^{-25}	12	1.41×10^{-25}	3×10^{-25}
6	2.92×10^{-25}	1.58×10^{-25}	13	1.24×10^{-25}	0.17×10^{-25}
7	4.73×10^{-25}	5.19×10^{-25}	14	6.36×10^{-26}	0.6×10^{-25}

Tabel 16: Hasil Denormalisasi

i	Output Denorm	Output Aktual	Galat
1	13.07099999997558	13.08	1.02×10^{-12}
2	9.109999999970457	9.11	1.13×10^{-12}
3	10.49999999996313	10.50	4.49×10^{-13}
		\vdots	
38	3.05999999996863	3.06	1.47×10^{-12}

di kabupaten/kota Provinsi Jawa Timur.

4. Kesimpulan

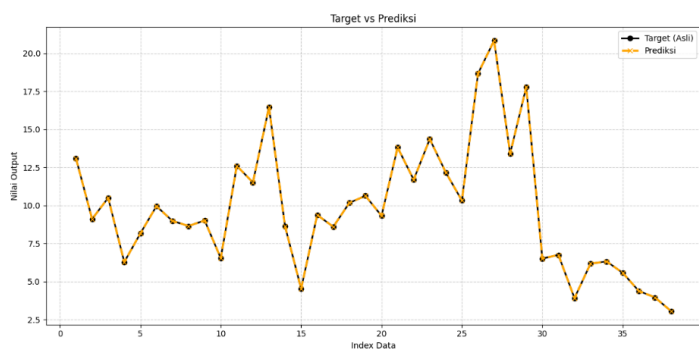
Penelitian ini menunjukkan bahwa metode *Adaptive Neuro-Fuzzy Inference System* (ANFIS) dapat diimplementasikan secara efektif untuk memprediksi tingkat kemiskinan di kabupaten/kota Provinsi Jawa Timur. Model yang dikembangkan menggunakan tiga variabel input, yaitu Tingkat Pengangguran Terbuka, laju pertumbuhan penduduk, dan Angka Partisipasi Sekolah usia 16–18 tahun, sedangkan variabel target berupa tingkat kemiskinan. Pendekatan *time-based split* digunakan agar proses pelatihan dan pengujian tetap mengikuti urutan waktu.

Hasil penelitian menunjukkan bahwa ANFIS menghasilkan kinerja prediksi yang sangat baik. Nilai MSE pada tahap pengujian sebesar 3.98×10^{-24} menunjukkan bahwa selisih antara hasil prediksi dan nilai aktual sangat kecil. Selain itu, proses pelatihan berhenti pada epoch ke-14 dengan MSE sebesar 6.36×10^{-26} karena telah memenuhi kriteria *early stopping*. Temuan ini menunjukkan bahwa kombinasi alur maju berbasis LSE dan alur mundur berbasis *backpropagation* mampu mengoptimalkan parameter konsekuen dan parameter premis secara efektif.

Secara keseluruhan, ANFIS terbukti mampu menangani pola data sosial ekonomi yang kompleks dan nonlinier. Metode ini dapat menjadi alternatif pendekatan prediktif untuk mendukung analisis kemiskinan di tingkat daerah. Penelitian lanjutan disarankan untuk menggunakan periode data yang lebih panjang, menambahkan variabel sosial ekonomi lain yang relevan, serta membandingkan kinerja ANFIS dengan metode prediksi lain agar diperoleh evaluasi yang lebih komprehensif.

Pernyataan Kontribusi Penulis

Tsalsya Ni'matul Aulia: Konseptualisasi, Metodologi, Penulisan–Draf Awal. **Evawati Alisah:** Kurasi Data, Analisis Formal, Penulisan–Telaah dan Penyuntingan. **Erna Herawati:** Validasi, Supervisi.



Gambar 1: Perbandingan Target dan Prediksi

Deklarasi Penggunaan AI atau Teknologi Berbasis AI

Tidak ada teknologi AI generatif atau berbasis AI yang digunakan dalam penulisan naskah ini.

Deklarasi Konflik Kepentingan

Penulis menyatakan tidak ada konflik kepentingan.

Pendanaan dan Ucapan Terima Kasih

Penelitian ini tidak menerima pendanaan eksternal. Penulis menyampaikan terima kasih kepada semua pihak yang telah memberikan saran dan dukungan selama proses penelitian ini. Ucapan terima kasih secara khusus disampaikan kepada pembimbing I, Ibu Evawati Alisah, dan pembimbing II, Ibu Erna Herawati.

Ketersediaan Data

Dataset yang dianalisis dalam studi ini tersedia secara publik pada laman BPS Jawa Timur¹.

Daftar Pustaka

- [1] Y. Huang. “Advances in artificial neural networks – methodological development and application”. In: *Algorithms* 2.3 (2009), pp. 973–1007. DOI: [10.3390/alg02030973](https://doi.org/10.3390/alg02030973).
- [2] Badan Pusat Statistik Provinsi Jawa Timur. *Poverty Profile of Jawa Timur Province 2023*. <https://jatim.bps.go.id/en/publication/2024/03/26/0a47f129594de9a197806916/profil-kemiskinan-provinsi-jawa-timur-2023.html>. Diakses 23 November 2024, 2024.
- [3] A. Yahya and R. E. Agustina. “Pembangunan desa dan tingkat kemiskinan kabupaten di Indonesia”. In: *Jurnal Litbang Sukowati* 6.1 (2022), pp. 98–108. DOI: [10.32630/sukowati.v6i1.329](https://doi.org/10.32630/sukowati.v6i1.329).
- [4] Sami S. Aldin and Hatice Sözer. “Comparative Analysis of ANN and ANFIS Models in Thermal Data Prediction”. In: *Journal of Advanced Computational Techniques* 11.1 (2022), pp. 45–56. DOI: [10.31462/jcemi.2022.02119139](https://doi.org/10.31462/jcemi.2022.02119139).
- [5] A. Matsniya et al. “Penerapan adaptive neuro fuzzy inference system (ANFIS) dalam prediksi produksi tembakau di Jember”. In: *InComTech: Jurnal* 13.1 (2023), pp. 51–68. DOI: [10.22441/incomtech.v13i1.15655](https://doi.org/10.22441/incomtech.v13i1.15655).
- [6] A. Wisudawaty and T. Djatna. “Penerapan ANFIS untuk Prediksi Penjualan Keripik Kacampiring”. In: *Indonesian Journal of Business and Technology* 12.1 (2024), pp. 45–52. DOI: [10.24961/j.tek.ind.pert.2024.34.1.1](https://doi.org/10.24961/j.tek.ind.pert.2024.34.1.1).
- [7] T. Rohana et al. “Kajian Model Backpropagation dan Hybrid ANFIS dalam Memprediksi Pertumbuhan Penduduk di Kabupaten Karawang”. In: *Journal of Information System Research (JOSH)* 4.2 (2023), pp. 374–381. DOI: [10.47065/josh.v4i2.2547](https://doi.org/10.47065/josh.v4i2.2547).
- [8] J. S. R. Jang. “ANFIS: Adaptive-Network-Based Fuzzy Inference System”. In: *IEEE Transactions on Systems, Man, and Cybernetics* 23.3 (1993), pp. 665–685. DOI: [10.1109/21.256541](https://doi.org/10.1109/21.256541).
- [9] R. Medar et al. “Impact of Training and Testing Data Splits on Accuracy of Time Series Forecasting in Machine Learning”. In: *2017 International Conference on Computing, Communication, Control and Automation (ICCCUBEA)*. 2017, pp. 1–6. DOI: [10.1109/ICCCUBEA.2017.8463779](https://doi.org/10.1109/ICCCUBEA.2017.8463779).
- [10] V. Cerqueira et al. “Evaluating time series forecasting models: an empirical study on performance estimation methods”. In: *Machine Learning* 109.11 (2020), pp. 1997–2028. DOI: [10.1007/s10994-020-05910-7](https://doi.org/10.1007/s10994-020-05910-7).
- [11] I. Lestari et al. “Pengaruh jumlah penduduk, tingkat pendidikan, dan upah terhadap pengangguran di Jawa Timur”. In: *INDEPENDENT: Journal of Economics* 4.2 (2024), pp. 141–148.
- [12] G. M. Putriaji et al. “Optimal Adaptive Neuro-Fuzzy Inference System Architecture for Time Series Forecasting with Calendar Effect”. In: *Sains Malaysiana* 51.9 (2022), pp. 2765–2777. DOI: [10.17576/jsm-2022-5109-23](https://doi.org/10.17576/jsm-2022-5109-23).
- [13] M. Bilgili et al. “One-day ahead forecasting of energy production from run-of-river hydroelectric power plants with a deep learning approach”. In: *Scientia Iranica* 29.4 (2022), pp. 1853–1867. DOI: [10.24200/SCI.2022.58636.5825](https://doi.org/10.24200/SCI.2022.58636.5825).
- [14] U. Sholihah. “Penerapan logika fuzzy Tsukamoto untuk memprediksi curah hujan di Kabupaten Kotawaringin Timur”. In: *EJECTS: E-Journal Computer, Technology and Informations System* 1.2 (2022), p. 78.
- [15] J. Heaton. “Review of: Goodfellow, Bengio, and Courville, Deep Learning”. In: *Genetic Programming and Evolvable Machines* 19.3 (2017), pp. 305–307. DOI: [10.1007/s10710-017-9314-z](https://doi.org/10.1007/s10710-017-9314-z).
- [16] A. R. Putra et al. “Level optimum hyperparameter tuning epoch dalam klasifikasi citra bencana kebakaran”. In: *Jurnal Teknologi Rekayasa (JTERA)* 7.2 (2022), pp. 209–216. DOI: [10.31544/jtera.v7.i2.2022.209-216](https://doi.org/10.31544/jtera.v7.i2.2022.209-216).

¹<https://jatim.bps.go.id/id>