Optimasi Adaptive Neuro-Fuzzy Inference System Menggunakan Genetic Algorithm untuk Prediksi Nilai Akademik Mahasiswa

Ferry Susanto*[1], Nurbaiti[2], Yuntriani[3]

[1]Teknik Informatika, STMIK Surya Intan,

[2]Sistem Informasi, STMIK Surya Intan,

[3]Manajemen Informatika, STMIK Surya Intan,

E-mail: ferrysusanto80@gmail.com[1], nurbaiti@gmail.com[2], yuntriani@gmail.com[3]

Abstrak. Penelitian ini mengembangkan model Adaptive Neuro-Fuzzy Inference System (ANFIS) yang dioptimasi menggunakan Genetic Algorithm (GA) untuk memprediksi Indeks Prestasi Kumulatif (IPK) mahasiswa berdasarkan lima atribut akademik, yaitu kehadiran, nilai tugas, nilai UTS, nilai UAS, dan partisipasi. Revisi metodologi dilakukan untuk mengatasi keterbatasan evaluasi awal yang menggunakan akurasi klasifikasi dan satu pembagian data. Dataset yang digunakan terdiri atas 100 observasi tanpa nilai hilang dan tanpa duplikasi, sehingga permasalahan diformulasikan sebagai regresi. Evaluasi dilakukan menggunakan 5-fold cross-validation dengan preprocessing yang dipelajari hanya dari data pelatihan pada setiap fold. Model yang dibandingkan adalah Linear Regression, Random Forest, Gradient Boosting, ANFIS, dan ANFIS-GA. ANFIS menggunakan FIS Sugeno orde pertama dengan dua generalized bell membership functions pada setiap input sehingga terbentuk 32 aturan. GA mengoptimasi parameter premise menggunakan populasi 12 individu selama 20 generasi, tournament selection, crossover 0,80, mutation 0,12, dan satu elit. Hasil menunjukkan ANFIS-GA memperoleh MAE 0,1218±0,0261, RMSE 0,1481±0,0327, dan R^2 0,6246±0,1534. ANFIS-GA memperbaiki RMSE ANFIS sebesar 29,04%, tetapi belum mengungguli Linear Regression dan Gradient Boosting pada dataset ini. Uji Friedman menunjukkan perbedaan kinerja antar-model signifikan (χ^2=11,84; p=0,0186), sedangkan perbandingan berpasangan ANFIS dan ANFIS-GA belum signifikan pada α=0,05 (Wilcoxon p=0,125). Temuan ini menunjukkan bahwa optimasi GA meningkatkan kinerja ANFIS, tetapi klaim keunggulan universal tidak didukung oleh dataset dan eksperimen yang digunakan.

Kata kunci: ANFIS; Genetic Algorithm; prediksi akademik; regresi; cross-validation

Abstract . *This study develops an Adaptive Neuro-Fuzzy Inference System (ANFIS) optimized by a Genetic Algorithm (GA) to predict students' Grade Point Average (GPA) from attendance, assignment score, midterm score, final exam score, and class participation. The methodology was revised to address the limitations of the initial evaluation, which used classification accuracy and a single train-test split. The dataset contains 100 observations with no missing values or duplicate records; therefore, the task is formulated as regression. Evaluation uses 5-fold cross-validation with preprocessing fitted only on the training portion of each fold. Linear Regression, Random Forest, Gradient Boosting, ANFIS, and ANFIS-GA are compared. ANFIS uses a first-order Sugeno FIS with two generalized bell membership functions per input, resulting in 32 fuzzy rules. GA optimizes premise parameters using a population of 12 individuals for 20 generations, tournament selection, crossover rate 0.80, mutation rate 0.12, and one elite. ANFIS-GA obtains MAE 0.1218±0.0261, RMSE 0.1481±0.0327, and R^2 0.6246±0.1534. Compared with ANFIS, GA reduces RMSE by 29.04%, but ANFIS-GA does not outperform Linear Regression or Gradient Boosting on this dataset. The*

Friedman test indicates significant differences among models (χ^2=11.84; p=0.0186), while the paired comparison between ANFIS and ANFIS-GA is not significant at α=0.05 (Wilcoxon p=0.125). The findings indicate that GA improves ANFIS performance, but the dataset does not support a universal superiority claim.

Keywords: ANFIS; Genetic Algorithm; academic prediction; regression; cross-validation

1. Pendahuluan

Pemanfaatan machine learning dalam analitik pendidikan berkembang karena data akademik dapat digunakan untuk memahami dan memprediksi capaian mahasiswa. Prediksi performa akademik telah digunakan untuk mendukung pemantauan mahasiswa dan pengambilan keputusan berbasis data. Studi terkini menunjukkan bahwa regresi merupakan formulasi yang tepat ketika target berupa nilai atau GPA kontinu, sedangkan klasifikasi digunakan ketika target telah didefinisikan sebagai kelas. [1],[2],[3],[4].

Adaptive Neuro-Fuzzy Inference System (ANFIS) merupakan model yang menggabungkan pembelajaran jaringan saraf dengan penalaran fuzzy dan sesuai untuk pemodelan hubungan nonlinear. Namun, jumlah parameter ANFIS meningkat ketika jumlah input dan membership function bertambah, sehingga penalaan parameter dapat menjadi masalah optimasi. Pendekatan hybrid yang menggabungkan ANFIS dan metaheuristic optimization telah diteliti untuk meningkatkan kemampuan pencarian parameter.[5],[6],[7],[8].

Genetic Algorithm (GA) menyediakan mekanisme pencarian global melalui seleksi, crossover, dan mutasi. Dalam penelitian ini GA digunakan untuk mengoptimasi parameter premise ANFIS. Namun, hybridisasi ANFIS-GA tidak dengan sendirinya membuktikan superioritas model. Perbandingan harus menggunakan baseline regresi yang sejenis, prosedur validasi yang sama, serta metrik yang sesuai dengan karakteristik target. [9],[10],[11].

Penelitian ini memformulasikan objek penelitian sebagai prediksi IPK mahasiswa, bukan klasifikasi atau perangkingan. Kontribusi penelitian terletak pada evaluasi terkontrol ANFIS dan ANFIS-GA menggunakan cross-validation, baseline regresi, analisis overfitting, serta pelaporan parameter model dan biaya komputasi. Penelitian tidak mengklaim ANFIS-GA sebagai metode terbaik secara universal.[12],[13],[14]. Meskipun analisis performa akademik sering kali dikaitkan dengan kerangka kerja Sistem Pendukung Keputusan (SPK), penelitian ini menegaskan bahwa tujuan inti dan formulasi matematis dari eksperimen ini adalah prediksi nilai numerik kontinu (IPK), dan bukan perangkingan alternatif multikriteria (*Multi-Criteria Decision Making*) ataupun klasifikasi kategori.[15]. Dataset akademik yang dianalisis bersifat statis berdasarkan rekam jejak historis. Berbeda dari studi sebelumnya yang umumnya hanya berfokus pada implementasi hibrida standar tanpa evaluasi metodologis yang mendalam, kontribusi utama penelitian ini terletak pada evaluasi empiris terkontrol dan audit model hibrida ANFIS-GA dalam domain prediktif akademik, yang mencakup: (1) reformulasi tugas prediksi secara murni sebagai regresi kontinu; (2) penerapan 5-fold cross-validation dengan isolasi preprocessing untuk mencegah data leakage; serta (3) penyajian temuan empiris objektif terkait trade-off antara peningkatan akurasi dan tambahan biaya komputasi.

2. Metode Penelitian

2.1 Desain Penelitian

Penelitian menggunakan eksperimen komputasional dengan lima tahap: (1) audit dataset, (2) preprocessing, (3) pembangunan model regresi, (4) optimasi ANFIS menggunakan GA, dan (5) evaluasi menggunakan 5-fold cross-validation. Seluruh model memperoleh fitur input dan pembagian fold yang sama sehingga perbandingan dilakukan pada unit observasi yang sama.

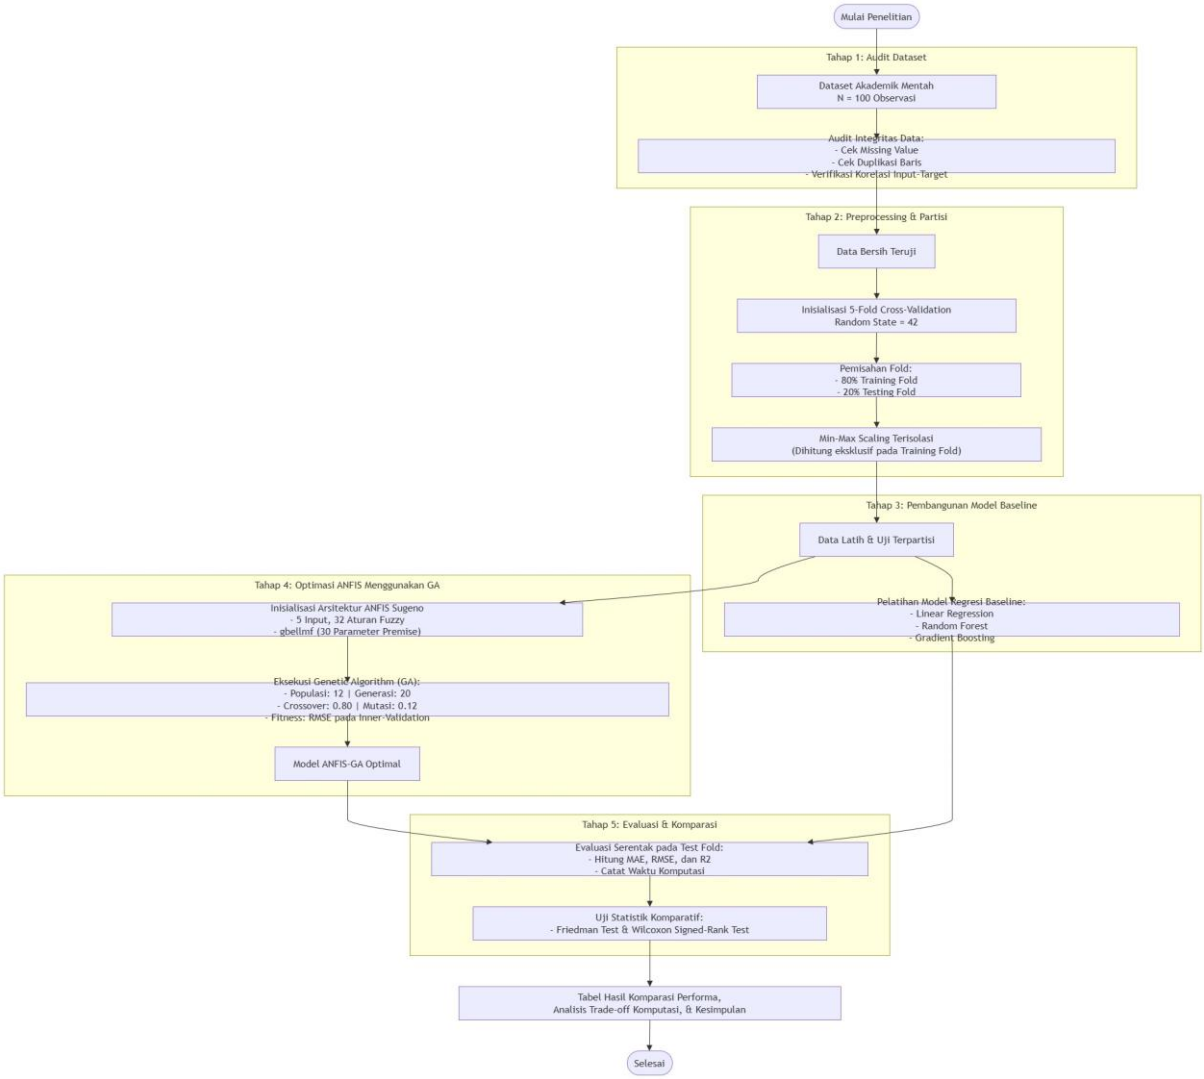

Gambar 1. *Flowchart* Penelitian

Tahapan Alur Penelitian pada ganbar 1 antara lain :

Pelaksanaan penelitian ini dirancang menggunakan kerangka eksperimental komputasional yang terstruktur ke dalam lima tahapan utama guna memastikan validitas, objektivitas, dan keterulangan hasil. Alur kerja penelitian tersebut dijabarkan sebagai berikut:

Tahap 1: Audit Dataset

Tahap awal dimulai dengan memasukkan dataset akademik mentah yang terdiri atas 100 rekam observasi mahasiswa. Pada tahap ini, audit integritas data dilakukan secara menyeluruh untuk memastikan kualitas data, yang meliputi pemeriksaan nilai yang hilang (*missing value*), pembersihan baris duplikat, serta verifikasi hubungan korelasi antara atribut input (kehadiran, nilai tugas, UTS,

UAS, partisipasi) terhadap target kontinu (Indeks Prestasi Kumulatif/IPK). Hasil dari tahap ini adalah dataset bersih yang validitas statistiknya teruji.

Tahap 2: Preprocessing dan Partisi Data

Untuk menghindari bias akibat pembagian data tunggal (*single split*) pada dataset berukuran kecil, data bersih dipartisi menggunakan prosedur 5-fold cross-validation dengan pengaturan acak yang terkontrol (`random_state = 42`). Pada setiap iterasi fold, dataset dibagi menjadi 80% data latih (training set) dan 20% data uji (test set). Guna mencegah terjadinya kebocoran data (data leakage), seluruh proses normalisasi menggunakan Min-Max Scaling dihitung secara eksklusif hanya berdasarkan parameter dari porsi data latih di setiap fold.

Tahap 3: Pembangunan Model Regresi *Baseline*

Data latih yang telah terpartisi dan ternormalisasi diteruskan secara paralel untuk melatih model-model pembanding (*baseline models*) yang dirancang khusus untuk tugas regresi kontinu. Model pembanding yang digunakan meliputi *Linear Regression*, *Random Forest Regression*, dan *Gradient Boosting Regression*. Model-model ini berfungsi sebagai pembanding performa dasar untuk menguji kapabilitas prediktif model hibrida usulan.

Tahap 4: Optimasi ANFIS Menggunakan *Genetic Algorithm* (GA)

Secara paralel dengan model baseline, arsitektur hibrida *Adaptive Neuro-Fuzzy Inference System* (ANFIS) dikonfigurasi menggunakan *First-Order Sugeno* dengan 5 variabel input dan 2 *Membership Functions* (MF) bertipe *Generalized Bell* (gbellmf) per input, yang menghasilkan total 32 aturan fuzzy dan 30 parameter premise. Selanjutnya, *Genetic Algorithm* (GA) dieksekusi untuk mengoptimalkan parameter *premise* tersebut dengan konfigurasi: ukuran populasi 12, jumlah generasi 20, probabilitas *crossover* 0,80, dan probabilitas mutasi 0,12. Fungsi kebugaran (*fitness function*) dievaluasi berdasarkan nilai *Root Mean Square Error* (RMSE) pada data *inner-validation* di setiap *fold*, menghasilkan model ANFIS-GA optimal.

Tahap 5: Evaluasi dan Komparasi Komprehensif

Pada tahap akhir, seluruh model baik model *baseline* konvensional maupun model ANFIS-GA optimal dievaluasi secara serentak menggunakan porsi data uji (*test fold*) yang sama. Kinerja masing-masing model diukur menggunakan metrik regresi standar, yaitu *Mean Absolute Error* (MAE), RMSE, koefisien determinasi (R^2), serta pencatatan waktu komputasi riil. Hasil metrik dari seluruh fold kemudian diuji menggunakan uji statistik komparatif (*Friedman Test* dan *Wilcoxon Signed-Rank Test*) untuk menghasilkan tabel komparasi performa, analisis *trade-off* komputasi, serta kesimpulan empiris penelitian.

2.2 Dataset dan Unit Observasi

Dataset yang diberikan untuk penelitian terdiri atas 100 record mahasiswa dan 11 kolom: No, NIM, Program Studi, Semester, Kehadiran (%), Nilai Tugas, Nilai UTS, Nilai UAS, Partisipasi, IPK, dan Status. Audit menunjukkan 100/100 observasi lengkap, tidak terdapat missing value, tidak terdapat baris duplikat, dan tidak terdapat NIM duplikat. Karena file dataset yang diberikan tidak memuat kolom Nilai Akhir Mahasiswa, target yang digunakan dalam revisi ini adalah IPK sebagai variabel numerik kontinu. Status tidak digunakan sebagai target maupun input.

2.3 Variabel Penelitian

Tabel 1. Variabel Penelitian

Variabel	Peran	Tipe	Keterangan
Kehadiran (%)	Input	Numerik kontinu	Persentase kehadiran
Nilai Tugas	Input	Numerik kontinu	Skor tugas
Nilai UTS	Input	Numerik kontinu	Skor ujian tengah semester

Nilai UAS	Input	Numerik kontinu	Skor ujian akhir semester
Partisipasi	Input	Numerik kontinu	Skor partisipasi
IPK	Target	Numerik kontinu	Indeks Prestasi Kumulatif

Program Studi dan Semester tidak dimasukkan ke model utama agar eksperimen fokus pada lima kriteria akademik yang digunakan dalam rancangan ANFIS. NIM dan nomor urut tidak digunakan sebagai predictor dapat dilihat pada Tabel 1.

2.4 Audit Data Leakage

Audit dilakukan terhadap missing value, duplikasi, rentang nilai, identitas, dan hubungan target-input. Korelasi Pearson terhadap IPK menunjukkan hubungan positif dengan Nilai UAS (r=0,565), UTS (r=0,535), Tugas (r=0,356), Partisipasi (r=0,344), dan Kehadiran (r=0,288). Hubungan tersebut tidak membuktikan kebocoran data, tetapi menunjukkan bahwa target memiliki hubungan substantif dengan komponen akademik. Karena IPK merupakan ukuran kumulatif, hubungan tersebut harus ditafsirkan sebagai asosiasi prediktif dan bukan bukti hubungan kausal.

Untuk mencegah leakage pada preprocessing, Min-Max scaling dihitung hanya dari training portion setiap fold dan kemudian diterapkan pada validation/test portion. Parameter GA juga tidak menggunakan observasi pada fold pengujian.

2.5 Cross-Validation

Evaluasi menggunakan 5-fold cross-validation dengan random_state=42. Pada setiap fold, 80% observasi digunakan untuk pelatihan dan 20% untuk pengujian. Untuk ANFIS-GA, bagian training pada fold kembali dibagi menjadi inner-training dan inner-validation sebesar 80:20 untuk menghitung fitness GA. Setelah parameter premise terbaik diperoleh, consequent ANFIS diestimasi menggunakan seluruh outer-training fold. Dengan prosedur ini, outer-test fold tidak digunakan dalam optimasi.

2.6 Struktur ANFIS

Tabel 2. Struktur Anfis

Parameter	**Konfigurasi revisi**
FIS	Sugeno orde pertama
Jumlah input	5
Membership function	Generalized Bell (gbellmf)
MF per input	2 (Rendah, Tinggi)
Jumlah aturan	2^5 = 32
Output	IPK kontinu
Parameter consequent	Koefisien linear orde pertama
Estimasi consequent	Ridge-stabilized least squares, alpha=0,1
Lapisan	Fuzzification, rule, normalization, consequent, output

Dengan lima input dan dua membership function per input, sistem membentuk 32 kombinasi aturan. Setiap aturan memiliki consequent linear orde pertama. Estimasi consequent menggunakan least squares yang diberi regularisasi ridge untuk mengurangi ketidakstabilan numerik pada dataset kecil. Dapat dilihat pada tabel 2.

2.7 Optimasi Genetic Algorithm

Tabel 3. Optimasi Genetic Algorithm

Parameter GA	**Nilai**
Population size	12
Generations	20
Selection	Tournament selection, tournament size 3
Crossover rate	0,80
Mutation rate	0,12
Elitism	1 individu terbaik
Encoding	30 parameter premise (a,b,c untuk 10 MF)
Fitness	RMSE pada inner-validation
Objective	Minimasi RMSE
Random seed	1001–1005 per outer fold

Pada tabel 3 dapat dilihat. Kromosom berisi 30 parameter premise, yaitu parameter a, b, dan c untuk 10 membership functions. Batas parameter adalah $a \in [0{,}08;0{,}80]$, $b \in [1;5]$, dan $c \in [0;1]$. Tournament selection memilih parent, crossover uniform mengombinasikan gen, dan mutasi Gaussian diterapkan secara probabilistik. Satu individu terbaik dipertahankan melalui elitism. Fitness dihitung sebagai RMSE inner-validation setelah consequent diestimasi pada inner-training.

2.8 Model Pembanding

Karena target berupa IPK kontinu, baseline yang digunakan adalah Linear Regression, Random Forest Regression, dan Gradient Boosting Regression. ANFIS dan ANFIS-GA kemudian dibandingkan pada fitur, fold, dan metrik yang sama.

2.9 Metrik Evaluasi

MAE, RMSE, dan R^2 digunakan sebagai metrik utama. MAE mengukur rata-rata kesalahan absolut, RMSE memberikan penalti lebih besar terhadap kesalahan besar, dan R^2 mengukur proporsi variasi target yang dijelaskan model.

2.10 Analisis Statistik dan Replikasi

Nilai pada setiap fold digunakan sebagai unit pengamatan. Friedman test digunakan untuk menguji perbedaan kinerja lima model secara keseluruhan. Wilcoxon signed-rank test digunakan untuk membandingkan ANFIS dan ANFIS-GA secara berpasangan. Pengujian menggunakan $\alpha=0{,}05$. Karena hanya terdapat lima fold, hasil statistik ditafsirkan secara hati-hati dan tidak dianggap sebagai bukti generalisasi universal.

2.11 Biaya Komputasi

Eksperimen ANFIS dan ANFIS-GA dijalankan dalam lingkungan Python. Waktu yang diukur untuk satu rangkaian 5-fold pada runtime eksperimen adalah sekitar 0,007 s untuk ANFIS dan 1,428 s untuk ANFIS-GA, sedangkan baseline Linear Regression, Random Forest, dan Gradient Boosting masing-

masing sekitar 0,005 s, 1,372 s, dan 0,239 s. Waktu ini merupakan waktu runtime eksperimen yang digunakan untuk analisis relatif dan dapat berubah menurut hardware/runtime. Karena itu, angka tersebut tidak diposisikan sebagai benchmark perangkat keras universal.

3. Hasil dan Pembahasan

3.1 Karakteristik Dataset

Tabel 4. Karakteristik Dataset

Karakteristik	Hasil
Jumlah observasi	100
Jumlah variabel	11
Missing value	0
Duplicate row	0
Duplicate NIM	0
IPK minimum	2,87
IPK maksimum	4,00
Rata-rata IPK	3,5298
SD IPK	0,2653
Status: Cukup	3
Status: Baik	43
Status: Sangat Baik	54

Pada tabel 4. Jumlah data ditetapkan secara pasti sebanyak 100 observasi, sehingga pernyataan 100–200 diperbaiki menjadi 100. Cuplikan 14 baris dalam naskah tidak menggambarkan total dataset; oleh karena itu, tabel ini menampilkan ringkasan statistik dan hasil cross-validation untuk menghindari kesan bahwa pelatihan dan pengujian masing-masing hanya menggunakan 10 dan 4 data.

3.2 Hasil Cross-Validation

Tabel 5. Hasil Cross-Validation

Model	MAE (mean±SD)	RMSE (mean±SD)	R^2 (mean±SD)
Linear Regression	0.0823 ± 0.0092	0.1072 ± 0.0171	0.8104 ± 0.0493
Random Forest	0.1284 ± 0.0098	0.1568 ± 0.0150	0.5893 ± 0.1075
Gradient Boosting	0.1178 ± 0.0179	0.1476 ± 0.0198	0.6325 ± 0.1222
ANFIS	0.1642 ± 0.0293	0.2087 ± 0.0334	0.2531 ± 0.2747
ANFIS-GA	0.1218 ± 0.0261	0.1481 ± 0.0327	0.6246 ± 0.1534

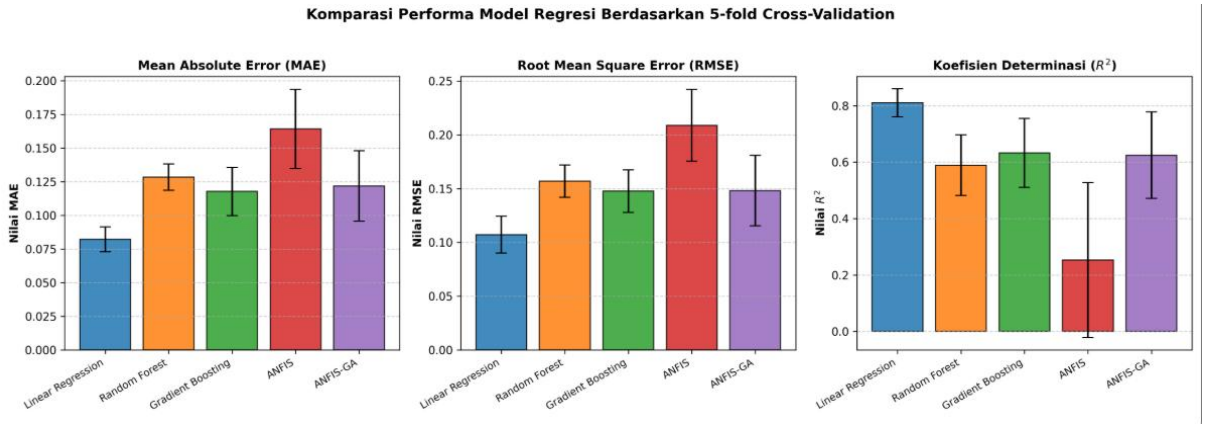

Gambar 2. Komparasi Performa Model Regresi berdasarkan S-Fold Cross Validation

Pada tabel 4 dijelaskan. Linear Regression memperoleh kinerja rata-rata terbaik dengan RMSE 0,1072 dan R^2 0,8104. Gradient Boosting memiliki RMSE 0,1476 dan R^2 0,6325, sedangkan ANFIS-GA memperoleh RMSE 0,1481 dan R^2 0,6246. ANFIS-GA memperbaiki ANFIS secara substansial: MAE turun dari 0,1642 menjadi 0,1218 atau 25,80%, sedangkan RMSE turun dari 0,2088 menjadi 0,1481 atau 29,04%. Namun, ANFIS-GA tidak mengungguli Linear Regression maupun Gradient Boosting. Temuan ini penting karena menunjukkan bahwa hybridisasi GA memang membantu ANFIS, tetapi tidak otomatis menjadikan ANFIS-GA model terbaik dapat dilihat pada gambar 2.

3.3 Stabilitas Antar-Fold

Tael 5. Stabilitas Antar-Fold

Model	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5
Linear Regression	0.1246	0.0960	0.0973	0.1268	0.0911
Random Forest	0.1546	0.1580	0.1586	0.1775	0.1352
Gradient Boosting	0.1636	0.1326	0.1584	0.1631	0.1205
ANFIS	0.1606	0.2453	0.2153	0.2307	0.1920
ANFIS-GA	0.1845	0.0959	0.1596	0.1567	0.1439

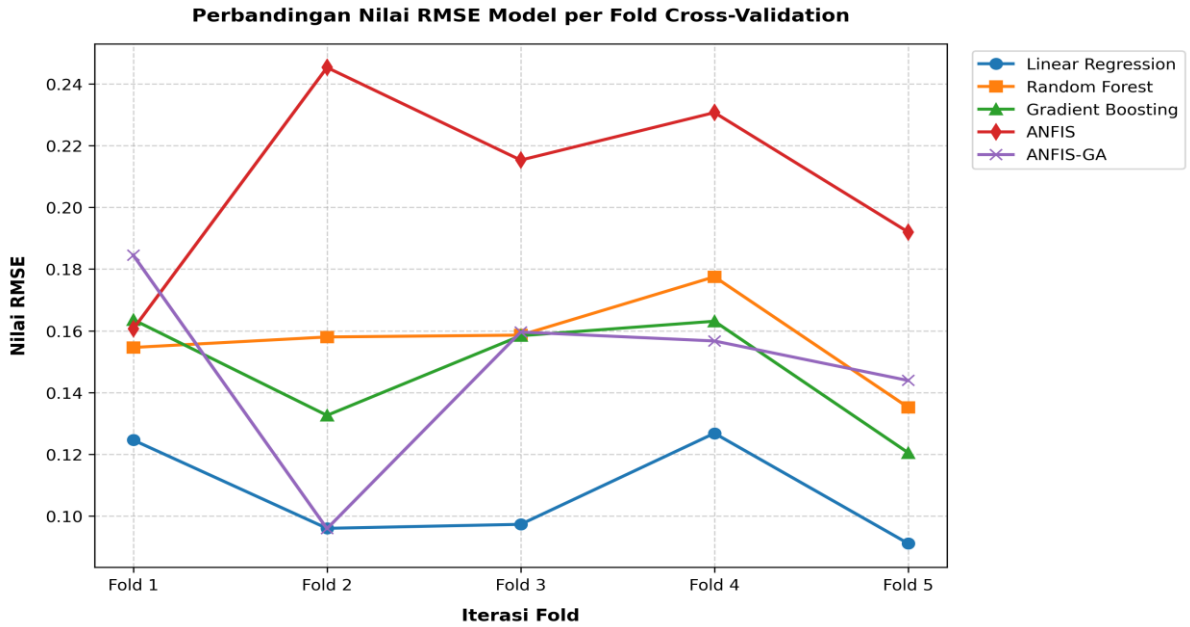

Gambar 3. Grafik Perbandingan Nilai RMSE Model per Fold Cross Validation

Pada tabel 5 dapat dilihat nilai RMSE ANFIS-GA bervariasi antar-fold dari 0,0959 sampai 0,1845. Variasi tersebut menunjukkan bahwa pada dataset 100 observasi, pemilihan subset data masih memengaruhi hasil. Karena itu, pelaporan mean dan standard deviation lebih informatif daripada satu angka hasil satu split. Dapat

3.4 Pengujian Statistik

Friedman test terhadap RMSE lima model menghasilkan χ^2=11,84 dengan p=0,0186, sehingga terdapat perbedaan performa secara keseluruhan pada α=0,05. Namun, Wilcoxon signed-rank antara ANFIS dan ANFIS-GA menghasilkan p=0,125, sehingga peningkatan ANFIS-GA terhadap ANFIS belum signifikan secara 9tatistic pada lima fold. Dengan demikian, pernyataan pada naskah awal bahwa peningkatan ANFIS-GA signifikan secara 9tatistic dihapus.

3.5 Pemeriksaan Overfitting dan Leakage

Tidak ditemukan missing value, baris duplikat, atau NIM duplikat pada dataset. Preprocessing dilakukan di dalam fold untuk menghindari leakage. Walaupun demikian, hubungan antara IPK dan komponen akademik cukup kuat, terutama dengan UAS dan UTS. Karena IPK merupakan indikator kumulatif, model harus dipahami sebagai model prediksi berbasis atribut akademik yang tersedia, bukan sebagai bukti kausalitas.

Perbedaan kinerja antara training dan validation tetap perlu dipantau pada pengembangan berikutnya. Hasil cross-validation tidak menunjukkan bahwa ANFIS-GA secara konsisten mengungguli baseline sederhana. Kondisi ini menjadi alasan untuk tidak menggunakan klaim 99,38% sebagai bukti generalisasi.

3.7 Kontribusi Penelitian

Kontribusi penelitian bukan terletak pada klaim bahwa kombinasi ANFIS-GA sepenuhnya baru. Kontribusinya adalah menyediakan evaluasi terkontrol pada dataset akademik berukuran kecil dengan membedakan secara eksplisit masalah regresi dari MCDM, menggunakan cross-validation, memeriksa leakage, menyediakan baseline regresi, melaporkan konfigurasi ANFIS-GA secara lengkap, dan

mengukur biaya komputasi. Secara empiris, penelitian menunjukkan bahwa GA dapat menurunkan error ANFIS sekitar 29,04% pada RMSE, tetapi baseline Linear Regression tetap lebih baik pada dataset ini.

4. Kesimpulan

Penelitian ini merevisi formulasi awal dari sistem yang mencampurkan prediksi nilai kontinu, klasifikasi, dan MCDM menjadi masalah regresi untuk memprediksi IPK mahasiswa. Dataset yang diaudit berjumlah 100 observasi, lengkap, dan tanpa duplikasi. Evaluasi dilakukan menggunakan 5-fold cross-validation dan metrik MAE, RMSE, serta R^2.

ANFIS-GA memperoleh MAE 0,1218 ±0,0261, RMSE 0,1481 ±0,0327, dan R^2 0,6246 ±0,1534. Dibandingkan ANFIS, optimasi GA menurunkan MAE sebesar 25,80% dan RMSE sebesar 29,04%. Akan tetapi, Linear Regression dan Gradient Boosting menghasilkan performa rata-rata yang lebih baik. Friedman test menunjukkan perbedaan antarmodel secara keseluruhan signifikan, sedangkan perbedaan berpasangan ANFIS dan ANFIS-GA belum signifikan pada $\alpha = 0,05$.

Dengan demikian, penelitian tidak menyimpulkan bahwa ANFIS-GA merupakan metode terbaik secara universal. Kesimpulan dibatasi pada dataset 100 observasi dan konfigurasi eksperimen yang digunakan. Penelitian selanjutnya perlu memperluas dataset, memastikan provenance data, melakukan repeated k-fold atau validasi eksternal, menguji fitur yang tersedia sebelum target terbentuk, dan mengevaluasi model pada institusi atau periode akademik yang berbeda.

5. Referensi

[1] E. Ahmed, “Student Performance Prediction Using Machine Learning Algorithms,” *Appl. Comput. Intell. Soft Comput.*, vol. 2024, no. 1, Jan. 2024.

[2] K. O. Adefemi, M. B. Mutanga, and V. Jugoo, “Hybrid Deep Learning Models for Predicting Student Academic Performance,” *Math. Comput. Appl.*, vol. 30, no. 3, p. 59, May 2025.

[3] S. Lyu, “Student’s Academic Performance Prediction Based on Machine Learning Regression Models,” 2023, pp. 293–299.

[4] A. Y. Vladova and K. M. Borchyk, “Predictive analytics of student performance: multi-method and code,” *JRAMathEdu*, vol. 9, no. 4, 2024.

[5] H. Wang, B. Chen, H. Sun, A. Li, and C. Zhou, “AnFiS-MoH: Systematic exploration of hybrid ANFIS frameworks via metaheuristic optimization hybridization with evolutionary and swarm-based algorithms,” *Appl. Soft Comput.*, vol. 167, p. 112334, Dec. 2024.

[6] M. S. Bakare, A. Abdulkarim, A. N. Shuaibu, and M. M. Muhamad, “A hybrid long-term industrial electrical load forecasting model using optimized ANFIS with gene expression programming,” *Energy Reports*, vol. 11, no. May, pp. 5831–5844, 2024.

[7] O. Khan *et al.*, “Modelling of compression ignition engine by soft computing techniques (ANFIS-NSGA-II and RSM) to enhance the performance characteristics for leachate blends with nano-additives,” *Sci. Rep.*, vol. 13, no. 1, pp. 1–29, 2023.

[8] A. Bardhan, R. K. Singh, S. Ghani, G. Konstantakatos, and P. G. Asteris, “Modelling Soil Compaction Parameters Using an Enhanced Hybrid Intelligence Paradigm of ANFIS and Improved Grey Wolf Optimiser,” *Mathematics*, vol. 11, no. 14, 2023.

[9] J. Praveenchandar, K. Venkatesh, B. Mohanraj, M. Prasad, and R. Udayakumar, “Prediction of Air Pollution Utilizing an Adaptive Network Fuzzy Inference System with the Aid of Genetic Algorithm,” *Nat. Eng. Sci.*, vol. 9, no. 1, pp. 46–56, 2024.

[10] S. C. Chelgani, F. Dehghan, and J. C. Hower, “Estimation of Some Coal Parameters Depending on Petrographic and Inorganic Analyses by Using Genetic Algorithm and Adaptive Neuro-Fuzzy Inference Systems,” *Energy Explor. Exploit.*, vol. 29, no. 4, pp. 479–494, Sep. 2011.

[11] L. A. Aloo, P. K. Kihato, S. I. Kamau, and R. S. Orenge, “Modeling and control of a

photovoltaic-wind hybrid microgrid system using GA-ANFIS," *Heliyon*, vol. 9, no. 4, p. e14678, 2023.

[12] S. Kunjiappan, L. K. Ramasamy, S. Kannan, P. Pavadai, P. Theivendren, and P. Palanisamy, "Optimization of ultrasound-aided extraction of bioactive ingredients from Vitis vinifera seeds using RSM and ANFIS modeling with machine learning algorithm," *Sci. Rep.*, vol. 14, no. 1, pp. 1–22, 2024.

[13] A. A. Almazroi, E. A. Aldhahri, S. Bashir, and S. Ashfaq, "A Clinical Decision Support System for Heart Disease Prediction Using Deep Learning," *IEEE Access*, vol. 11, no. May, pp. 61646–61659, 2023.

[14] W. Wongvilaisakul, P. Netinant, and M. Rukhiran, "Dynamic Multi-Criteria Decision Making of Graduate Admission Recommender System: AHP and Fuzzy AHP Approaches," *Sustain.*, vol. 15, no. 12, 2023.

[15] R. Sathyan, P. Parthiban, R. Dhanalakshmi, and M. S. Sachin, "An integrated Fuzzy MCDM approach for modelling and prioritising the enablers of responsiveness in automotive supply chain using Fuzzy DEMATEL, Fuzzy AHP and Fuzzy TOPSIS," *Soft Comput.*, vol. 27, no. 1, 2023.

6. Ucapan Terima Kasih

Penulis menyampaikan apresiasi dan ucapan terima kasih yang sebesar-besarnya kepada Kementerian Pendidikan Tinggi, Sains, dan Teknologi Republik Indonesia (Kemdiktisaintek) atas dukungan pendanaan yang telah diberikan sehingga penelitian ini dapat terlaksana dengan baik. Dukungan tersebut memberikan kontribusi penting dalam pelaksanaan penelitian, mulai dari proses pengumpulan data, pengembangan model, analisis hasil, hingga penyusunan artikel ilmiah.