



Evaluasi Kinerja Machine Learning dalam Memprediksi Kemampuan Adaptasi Mahasiswa pada Lingkungan Pembelajaran Daring

Shindy Arti¹, Elan Suherlan²

¹Sistem dan Teknologi Informasi, Fakultas Teknik, Universitas Negeri Jakarta

²Teknik Informatika, Fakultas Teknologi Informasi, Universitas YARSI

¹shindyarti@unj.ac.id. ²elansuherlan@yarsi.ac.id

Abstract

The development of artificial intelligence drives massive transformation on online learning where students' adaptability plays a crucial factor in successful learning. This study aims to evaluate the ability of machine learning algorithms to predict the level of student adaptation to online learning. The data used comes from 675 higher education students, then processed using Python and Orange 3.8. The development method used in this study refers to the CRISP-DM method. There are five stages carried out, namely business understanding, data understanding, data preparation, modeling, and evaluation of model performance. Of the seven supervised learning algorithms used, the Neural Network algorithm has the best performance overall and per level of adaptation (high, medium, low), with the highest accuracy of 0.946. This study also identifies the main factors of adaptation using the Decision Tree algorithm, with class duration as the dominant differentiator. Recommendations for further research include feature selection, data balancing, and development of user-based interactive systems.

Keywords: student adaptation level, online learning, machine learning model evaluation, neural network

Abstrak

Perkembangan kecerdasan buatan mendorong transformasi pembelajaran daring yang adaptif, di mana kemampuan adaptasi mahasiswa menjadi faktor krusial dalam keberhasilan belajar. Penelitian ini bertujuan mengevaluasi kemampuan algoritme machine learning dalam memprediksi tingkat adaptasi mahasiswa terhadap pembelajaran online. Data yang digunakan berasal dari tingkat pendidikan tinggi sebanyak 675 data mahasiswa, kemudian diolah menggunakan Python dan Orange 3.8. Metode pengembangan yang digunakan dalam penelitian ini merujuk pada metode CRISP-DM. Terdapat lima tahapan yang dilakukan yaitu kejelasan alur bisnis, pemahaman data, persiapan data, pemodelan dan evaluasi kinerja model. Dari tujuh algoritma supervised learning digunakan, algoritma *Neural Network* memiliki performa terbaik secara keseluruhan maupun per tingkat adaptasi (tinggi, sedang, rendah), dengan akurasi tertinggi sebesar 0,946. Penelitian ini juga mengidentifikasi faktor utama adaptasi menggunakan algoritma *Decision Tree*, dengan durasi kelas sebagai pembeda dominan. Rekomendasi penelitian selanjutnya mencakup seleksi fitur, penyeimbangan data, dan pengembangan sistem interaktif berbasis pengguna.

Kata kunci: Tingkat Adaptasi Mahasiswa, Pembelajaran Online, Evaluasi Model machine learning, neural network

© 2025 Jurnal Pustaka AI

1. Pendahuluan

Artificial intelligence atau kecerdasan buatan sangat berkembang pesat di berbagai ilmu. Berkembangnya

algoritme *machine learning* dan *deep learning* mendorong percepatan transformasi di banyak industri, termasuk pendidikan. Sejak masa pandemi, setiap institusi mengadopsi e-learning sebagai metode

utama dalam pembelajaran. Sejalan dengan ciri khas AI dalam *education 4.0* dan *society 5.0* yaitu terciptanya lingkungan pembelajaran yang adaptif. Pembelajaran yang adaptif ini memanfaatkan data *real-time* untuk menyesuaikan kecepatan, konten, dan penyampaian pembelajaran berdasarkan kinerja dan penguasaan konsep mahasiswa [1], [2].

Hasil penelitian yang dilakukan oleh *she et al.* menyatakan bahwa kemampuan manajemen diri mahasiswa akan mempengaruhi keberhasilan dalam pembelajaran siswa yang memiliki kemampuan yang baik untuk beradaptasi dengan persyaratan pembelajaran baru dan rencana kurikulum akan memiliki pemahaman yang baik tentang pengendalian tugas belajar yang diperlukan untuk pembelajaran mandiri [3]. Kemampuan beradaptasi ini memastikan bahwa mahasiswa mengalami kemajuan sesuai dengan kecepatan mereka sendiri, menerima dukungan atau tantangan tambahan sesuai kebutuhan, sehingga mendorong pengalaman pendidikan yang lebih inklusif dan efektif [1]. Dengan melakukan prediksi kemampuan adaptasi mahasiswa dalam pembelajaran *online* dapat mengukur tingkat penerimaan mahasiswa dan kedepannya dapat membantu meningkatkan pengalaman belajar mahasiswa.

Beberapa penelitian melakukan prediksi kemampuan adaptasi mahasiswa banyak menggunakan algoritme *machine learning*. Penelitian yang dilakukan oleh Suzan [4] membandingkan algoritme *decision tree*, *random forest*, naïve bayes, support vector machine, k-nearest neighbour, dan artificial neural network. Dalam perbandingan tersebut, algoritme *random forest* mendapatkan hasil akurasi rata-rata tertinggi yaitu sebesar 89.63%. Dengan menggunakan dataset yang sama, penelitian yang dilakukan oleh Sree *et al.* [5] mengatasi ketidakseimbangan data menggunakan SMOTE *over-sampling* dan algoritme *machine learning* yang diterapkan yaitu k-nearest neighbor, *random forest*, support vector machine, *logistic regression* dan XGBoost *classifier*. Penggunaan teknik SMOTE *over sampling* mampu meningkatkan performa akurasi rata-rata algoritme. Algoritme *random forest* dan XGBoost memiliki nilai akurasi tertinggi sebesar 92%. Selain teknik penanganan data, seleksi fitur dan pengubahan parameter dapat membantu algoritme untuk memprediksi pola tersembunyi pada data.

Saat ini, pembelajaran *online* tidak hanya menjadi alternatif dibandingkan pembelajaran tatap muka karena telah menjadi alat yang sangat diperlukan bagi banyak kalangan. Namun pembelajaran *online* juga menimbulkan banyak tantangan bagi mahasiswa, terutama dalam hal kemampuan beradaptasi dengan lingkungan pembelajaran yang baru. Telli dkk. [6] dalam hasil penelitiannya menjelaskan bahwa terdapat perubahan pola adopsi inovasi dimana

pandemi mempercepat transformasi digital dan penerimaan inovasi di masyarakat.


Identifikasi awal terhadap peserta didik dapat menjadi kunci untuk memberikan mereka dukungan yang tepat dan meningkatkan keberhasilan akademis [7]. Kemampuan beradaptasi pembelajaran *online* adalah konsep yang kompleks dan multidimensi. Namun, keterbatasan teknologi ada, dan teknik ini bukan yang terbaik untuk pembelajaran praktis. Gaya pembelajaran harus dievaluasi berdasarkan pendekatan yang menekankan hasil pembelajaran. Teknik hybrid learning dieksplorasi karena metode ceramah, meski belum optimal, tetap diperlukan namun terkadang diabaikan dalam kursus *online* [8]. Secara umum, ini dianggap sebagai kemampuan siswa untuk menyesuaikan strategi belajar, perilaku, sikap dan di antaranya adalah keakraban mereka dengan alat teknologi yang mereka gunakan [9], [10].

Berdasarkan latar belakang dan penelitian terdahulu yang telah diuraikan, peneliti bermaksud untuk mengevaluasi kemampuan adaptasi mahasiswa algoritme machine learning.

2. Metode Penelitian

2.1 Metode CRISP-DM

CRISP-DM (Cross-Industry Standard Process for Data Mining) adalah metode standar yang digunakan dalam proses penggalian data untuk menghasilkan wawasan dari data secara sistematis. Metode ini terdiri dari enam tahapan utama.



Gambar 1. Enam Tahapan CRISP-DM

Tahap pertama adalah *business understanding* atau pemahaman konteks bisnis yang berfokus pada pemahaman tujuan bisnis dan kebutuhan proyek. Selanjutnya adalah *data understanding* atau interpretasi data untuk mengumpulkan dan mengeksplorasi data guna memahami struktur dan kualitasnya. Tahap ketiga adalah *data preparation* atau pengolahan data yang mencakup pembersihan, transformasi, dan penggabungan data agar siap digunakan untuk pemodelan. Tahap berikutnya adalah *modeling* atau pengembangan model, di mana tim membangun model menggunakan teknik data mining seperti klasifikasi, regresi, atau klusterisasi. Setelah itu, tahap *evaluation* atau pengujian model dilakukan untuk menguji kinerja model dan

memastikan hasilnya selaras dengan tujuan bisnis. Tahap terakhir adalah *deployment* atau implementasi sistem di mana model yang telah dievaluasi diimplementasikan ke dalam proses bisnis untuk menghasilkan keputusan berbasis data.

2.2 Algoritma Machine Learning

Machine learning menggambarkan kapasitas sistem untuk mampu belajar dari data dalam menemukan pola-pola tersembunyi. Penerapan *machine learning* dapat mengotomasi proses pembuatan model analitis dan menyelesaikan tugas-tugas yang diberikan [11]. Beberapa algoritme *machine learning* sebagai berikut:

1) *Random forest*

Random forest digunakan untuk model klasifikasi dan regresi. Model ini terdiri dari serangkaian pohon keputusan, yang masing-masing pohon dilatih dengan subset data acak dan memberikan vote sebagai hasil klasifikasi [9].

2) *Decision tree*

Decision tree dibangun seperti struktur flow-chart pohon, dimana setiap simpul internal mewakili suatu fitur dan simpul daun yang mewakili keluaran akhir yang sesuai. Algoritme *decision tree* paling umum digunakan karena pengelompokan kumpulan data yang mudah dipahami, cepat dan efektif dengan algoritme klasifikasi lainnya. Struktur *decision tree* dimulai dengan node akar dan melibatkan pemisahan data menjadi subset yang lebih kecil yang berisi instance dengan nilai serupa menggunakan perhitungan entropi [4].

3) *Logistic regression*

Logistic regression adalah algoritme yang banyak digunakan untuk klasifikasi biner. Model ini memodelkan probabilitas titik data termasuk dalam kelas positif atau negatif menggunakan fungsi logistik. Model dilatih menggunakan metode optimasi seperti *gradient descent*. Algoritme *logistic regression* merupakan algoritme yang sederhana dan mudah dipahami namun memiliki keterbatasan dengan data non linear dan sensitif terhadap outlier [12].

4) *Support Vector Machine*

Support Vector Machine (SVM) adalah algoritma yang menggunakan ruang hipotesis berupa fungsi-fungsi linier dalam sebuah ruang fitur yang berdimensi tinggi. Cara kerja SVM untuk mengklasifikasikan sesuatu menggunakan decision boundary dengan prinsip *Structural Risk Minimization (SRM)*. SRM bertujuan untuk menjamin batas atas dari generalisasi pada data pengujian dengan cara mengontrol kapasitas dari hipotesis hasil pembelajaran [13].

5) *Naïve Bayes*

Naïve Bayes adalah metode klasifikasi yang paling sederhana dengan menggunakan konsep peluang, dimana setiap atribut contoh (data sampel) bersifat

saling lepas satu sama lain berdasarkan atribut kelas [14].

6) *kNN*

k-Nearest Neighbor (kNN) merupakan sebuah metode *supervised learning* yang memiliki tujuan mengkategorikan data berdasarkan mayoritas kelas dari tetangga terdekat yang ditemukan. Konsep dasar dari k-NN adalah mencari jarak terdekat antara data yang akan dievaluasi dengan K tetangga terdekatnya dalam data pelatihan menggunakan jarak Euclidean [15].

7) *Neural Network*

Neural Network (ANN) disebut juga jaringan saraf tiruan adalah salah satu algoritma klasifikasi yang mensimulasikan jaringan saraf biologis, dimana model memiliki banyak layer dan bersifat non-linear. Neural network memiliki hidden layer yang berfungsi untuk mengklasifikasikan data seperti model neuron yang terhubung ke banyak neuron yang lain [11].

8) *Gradient Boosting*

Gradient Boosting adalah algoritma ensemble yang bekerja dengan cara memperkecil kesalahan model secara bertahap. Teknik ini menggabungkan beberapa model yang kurang optimal menjadi sebuah model yang kuat. Pada setiap iterasi, algoritma gradient Boosting akan mengoptimalkan suatu fungsi objektif dengan mengevaluasi gradient pada setiap titiknya [16].

3. Data Penelitian

Dataset yang digunakan diperoleh dari platform kaggle yang digunakan untuk tujuan mengevaluasi dan efektivitas pendidikan digital, khususnya fitur yang menggambarkan faktor adaptasi mahasiswa. Dataset yang digunakan dalam studi ini berasal dari kuesioner online dan offline [4]. Dataset diambil dari periode 10 Desember 2020 hingga 5 Februari 2021. Secara keseluruhan, dataset berisi 1205 baris yang mencakup 14 variabel. 14 variabel tersebut ditunjukkan pada Tabel 1. Penilaian ini mencakup pemeriksaan statistik mendetail dari parameter fokus 'Tingkat Adaptasi' seperti yang digambarkan dalam representasi grafis pada Gambar 1, yang mencakup tidak hanya tiga klasifikasi berbeda yaitu Medium, Rendah, dan Tinggi, tetapi juga frekuensi dan proporsinya masing-masing. Analisis yang ketat ini bertujuan untuk mengungkap korelasi antara berbagai atribut pembelajaran digital dan keseluruhan kemampuan adaptasi yang ditunjukkan oleh peserta didik, menawarkan wawasan berharga untuk mengoptimalkan praktik pendidikan dalam lanskap digital.

Tabel 1. Deskripsi Dataset Penelitian

No.	Variabel	Nilai Unik	Nilai	Deskripsi
1	Jenis Kelamin	2	Perempuan (0), Laki-Laki (1)	Jenis kelamin
2	Usia	6	1 sampai 5 (0), 6 sampai 10 (1), 11 sampai 15 (2), 16 sampai 20	Rentang usia siswa

			(3), sampai 21 (4), 26 sampai 25 (5), 30+(6)	
3	Tingkat Pendidikan	3	School (0), College (1), University (2)	Tingkat pendidikan
4	Jenis Institusi	2	Swasta (0), Negeri (1)	Jenis institusi pendidikan
5	Siswa IT	2	Tidak (0), Iya (1)	Sebagai Siswa IT
6	Lokasi	2	Tidak (0), Iya (1)	Lokasi siswa di kota
7	Pemadaman Listrik	2	Rendah (0), Tinggi (1)	Tingkat Pemadaman
8	Kondisi Ekonomi	3	Rendah (0), Menengah (1), Tinggi (2)	Kondisi ekonomi keluarga
9	Tipe internet	2	2G (0), 3G (1), 4G (2)	Jenis Internet
10	Perangkat	3	Tab (0), Mobile (1), Komputer (2)	Perangkat yang digunakan
11	Jenis jaringan	3	Mobile Data (0), Wifi (1)	Jenis jaringan
12	Durasi Kelas	2	0 (0), 1 sampai 3 jam (1), 3 sampai 6 jam (2)	Durasi kelas
13	Self LMS	3	Tidak (0), Iya (1)	Ketersediaan LMS
14	Tingkat Adaptabilitas	3	Low (0), Moderate (1), High (2)	Tingkat Adaptabilitas Mahasiswa

Data awal yang didapatkan sebesar 1025 data dengan tiga kategori tingkat pendidikan yaitu Universitas (456 data), Politeknik (219 data) dan Sekolah (530 data). Kemampuan tingkat adaptasi siswa pada data adalah menengah. Pada penelitian ini, peneliti fokus untuk menggali data mahasiswa di tingkat pendidikan tinggi yaitu universitas dan politeknik, dimana total data yang digunakan sejumlah 675 data. Rangkuman data dan nilai unik pada data yang diolah ditunjukkan pada gambar 2.


	count	unique	top	freq
Gender	675	2	Boy	392
Age	675	3	21-25	374
Education Level	675	2	University	456
Institution Type	675	2	Non Government	393
IT Student	675	2	No	398
Location	675	2	Yes	453
Load-shedding	675	2	Low	505
Financial Condition	675	3	Mid	542
Internet Type	675	2	Wifi	375
Network Type	675	3	4G	464
Class Duration	675	3	1-3	391
Self Lms	675	2	No	468
Device	675	3	Mobile	496
Adaptivity Level	675	3	Moderate	324

Gambar 2. Rangkuman Data Penelitian

Gambar 2 menunjukkan distribusi data dari 675 responden yang mayoritas merupakan mahasiswa universitas berusia 21–25 tahun (374 orang), dengan dominasi jenis kelamin laki-laki (392 orang). Sebagian besar berasal dari institusi non-pemerintah (393 orang) dan bukan mahasiswa jurusan IT (398 orang). Dari segi lokasi, mayoritas responden tinggal di area dengan akses internet yang baik (453 orang) serta mengalami pemadaman listrik yang rendah (505 orang). Kondisi ekonomi responden didominasi oleh kelompok menengah (542 orang), yang mencerminkan latar belakang finansial yang relatif stabil. Dalam hal akses terhadap teknologi, sebagian besar responden menggunakan WiFi (375 orang) dan jaringan 4G (464 orang), serta perangkat mobile (496 orang) sebagai media utama untuk kegiatan pembelajaran. Durasi kelas yang paling umum adalah 1–3 jam per sesi (391 orang), dan mayoritas responden tidak menggunakan LMS (Learning Management System) pribadi (468 orang). Tingkat adaptasi terhadap pembelajaran digital sebagian besar berada pada kategori sedang (moderate), yaitu sebanyak 324 orang. Data ini mengindikasikan bahwa meskipun responden memiliki akses teknologi yang cukup baik, terdapat potensi peningkatan dalam penggunaan LMS dan peningkatan adaptasi terhadap pembelajaran berbasis digital.

4. WorkFlow Penelitian

Workflow dalam penelitian ini dapat dilihat pada gambar 3. Workflow dibawah menggambarkan proses data mining yang dimulai dari pengumpulan dan eksplorasi data, dilanjutkan dengan pemrosesan, pemodelan, evaluasi, dan penerapan model. Penelitian menggunakan bahasa python dan aplikasi data mining yaitu orange versi 3.8.




Gambar 3. Workflow Penelitian

Proses dimulai dengan mengambil data dari sumber tertentu (ditunjukkan oleh node *File*) yang kemudian dianalisis melalui fitur seperti *Data Info*, *Feature Statistics*, *Distributions*, dan *Rank* untuk memahami struktur dan karakteristik data. Setelah itu, data diproses melalui tahap *Preprocess* untuk membersihkan dan mengatur ulang data agar siap digunakan dalam proses pemodelan. Pada tahap pemodelan, berbagai algoritma seperti *SVM* (*Support Vector Machine*), *Logistic Regression*, *Naive Bayes*, *Gradient Boosting*, dan *Tree* digunakan untuk membangun model berdasarkan data yang telah diproses. Model yang dihasilkan kemudian dievaluasi menggunakan *Test and Score* untuk mengukur kinerjanya, dan hasil evaluasi divisualisasikan dalam bentuk *Confusion Matrix* untuk memahami tingkat akurasi dan kesalahan model. Kemudian model dianalisis lebih lanjut dengan *Tree Viewer* untuk memahami struktur model.

5. Hasil dan Pembahasan

Variabel-variabel dari dataset yang digunakan bersifat kategorikal sehingga proses data transformation yang dilakukan pertama adalah mengubah jenis data menjadi bentuk diskrit dan ordinal. Proses ini dilakukan melalui fitur *Continueize* di Orange yang berfungsi untuk mengubah data kategorikal menjadi data numerik agar dapat diproses algoritma yang memerlukan input berupa angka. Setelah data berhasil diubah menjadi bentuk diskrit, opsi *Treat as Ordinal* dapat digunakan untuk mengatur hasil diskritisasi sebagai data ordinal, yang berarti nilai dari kategori akan memiliki arti urutan tertentu. Dalam pengaturan ini, nilai kategori hasil diskritisasi akan direpresentasikan sebagai angka yang memiliki makna urutan. Sebagai contoh, jika hasil diskritisasi terdiri dari tiga kategori, seperti Rendah, Sedang dan Tinggi, maka ketiga kategori tersebut akan diubah menjadi nilai numerik seperti **1**, **2**, dan **3**. Dalam hal ini, algoritma akan memperlakukan nilai 3 sebagai lebih tinggi daripada 2, dan 2 lebih tinggi daripada 1, sehingga algoritma dapat memahami adanya struktur hierarkis dalam data. Pengaturan ini memungkinkan algoritma untuk memanfaatkan informasi urutan antar kategori,

sehingga model dapat mengenali pola hubungan dalam data dengan lebih baik.



Gambar 4. Tampilan Preprocessing Data

Adaptability Level	Gender	Age	Education Level	Institution Type	IT Student	Location	Last checking	Financial Condition	Internet Type	Network Type
1	Male	2	2	1	0	1	1	0	1	1
2	Male	4	2	1	0	1	0	0	0	0
3	Male	1	4	2	1	0	1	1	0	1
4	Male	0	5	2	1	0	1	1	0	1
5	Low	1	5	2	0	0	1	1	0	1
6	Male	0	4	2	1	0	1	0	0	0
7	Low	1	3	0	1	0	1	1	0	1
8	Male	0	3	0	0	0	1	1	0	0
9	Male	0	4	2	1	0	1	1	0	1
10	Low	1	3	0	0	0	0	0	0	0
11	Male	0	2	1	1	0	1	1	0	0
12	Low	0	4	0	0	0	0	1	0	0
13	Male	1	2	1	1	0	1	1	0	0
14	Male	0	3	0	0	0	1	1	0	1
15	Male	0	2	1	1	0	1	1	0	0
16	High	0	4	2	1	0	1	1	1	0
17	Male	0	2	1	1	0	1	1	0	0
18	Male	1	3	0	1	0	1	0	0	1
19	Male	1	0	1	1	0	1	1	1	0
20	High	0	4	2	1	1	1	0	1	1
21	Low	0	5	2	0	0	0	1	1	0
22	Low	1	2	1	1	0	1	0	0	1
23	High	0	4	2	1	0	0	0	1	0
24	Male	0	4	2	1	1	1	1	0	1
25	Low	0	4	2	1	1	1	1	0	0
26	Low	0	2	1	1	0	1	0	1	1
27	Low	0	0	1	0	0	1	0	0	0
28	Male	0	4	2	1	1	1	1	0	1

Gambar 5. Data yang telah ditransformasikan

Selain *data transformation*, *data splitting* merupakan satu langkah penting sebelum masuk ke dalam tahap pemodelan. *Data splitting* menjadi bagian dari data preprocessing yang bertujuan untuk membagi dataset menjadi beberapa bagian agar model machine learning dapat dilatih dan dievaluasi dengan baik. Dalam proses ini, dataset dibagi menjadi training set (data pelatihan) dan test set (data pengujian) dengan rasio tertentu. Training set digunakan untuk melatih model dalam mengenali pola dan hubungan antar fitur, sedangkan test set digunakan untuk mengevaluasi performa model pada data yang belum pernah digunakan sebelumnya sehingga dapat mengukur kemampuan generalisasi model. Proses ini termasuk dalam tahap preprocessing karena pemisahan data untuk memastikan model dapat belajar dengan efektif dan memberikan hasil prediksi yang akurat. Dalam penelitian ini, pemisahan dataset dilakukan dengan perbandingan 80:20 untuk data training dan data testing. Setelah model dilatih, model diuji menggunakan data pengujian yang sebelumnya tidak pernah dilihat oleh model untuk menilai sejauh mana model mampu melakukan prediksi dengan benar. Pemodelan kinerja algoritma machine learning menggunakan 10-cross validation untuk mengurangi bias dan mengurangi variansi karena banyak melibatkan kombinasi data. Metrik evaluasi yang digunakan dalam melihat hasil pemodelan yaitu menggunakan akurasi, precision, recall, F1-score, dan matthews correlation coefficient (MCC).

Tabel 2. Metrik Evaluasi Pemodelan Machine Learning

Metrik Evaluasi	Deskripsi
<i>AUC (Area Under Curve)</i>	Kemampuan model untuk membedakan antara kelas positif dan negatif.
<i>CA (Classification Accuracy)</i>	Persentase prediksi yang benar dibandingkan dengan total data. Nilai tinggi menunjukkan bahwa model dapat memprediksi dengan tepat sebagian besar data.
<i>F1 Score</i>	Harmonic mean antara Precision dan Recall . F1 score tinggi menunjukkan keseimbangan yang baik antara false positives dan false negatives .
<i>Precision</i>	Proporsi prediksi positif yang benar terhadap total prediksi positif. Nilai tinggi berarti model jarang memberikan prediksi positif yang salah.
<i>Recall</i>	Proporsi prediksi positif yang benar terhadap total data positif sebenarnya. Nilai tinggi berarti model mampu menangkap sebagian besar kasus positif yang ada.
<i>MCC (Matthews Correlation Coefficient)</i>	Mengukur korelasi antara hasil prediksi dan label sebenarnya, memperhitungkan true positive , false positive , true negative , dan false negative .

Berdasarkan model yang telah dilatih, hasil evaluasi pemodelan dari berbagai algoritma yang digunakan dapat dilihat pada gambar 7, gambar 8, gambar 9 dan gambar 10.

Evaluation results for target (None, show average over classes)							
Model	AUC	CA	F1	Prec	Recall	MCC	
Random Forest	0.934	0.830	0.829	0.833	0.830	0.700	
Logistic Regression	0.788	0.711	0.711	0.712	0.711	0.491	
Gradient Boosting	0.919	0.830	0.829	0.831	0.830	0.700	
kNN	0.902	0.756	0.755	0.755	0.756	0.572	
Neural Network	0.946	0.861	0.860	0.863	0.861	0.754	
SVM	0.896	0.796	0.795	0.803	0.796	0.644	
Naive Bayes	0.776	0.680	0.679	0.680	0.680	0.441	
Tree	0.938	0.865	0.865	0.865	0.865	0.764	

Gambar 6. Hasil Evaluasi Pemodelan terhadap Kelas Rata-rata

Berdasarkan hasil evaluasi rata-rata seluruh kelas, model Neural Network menunjukkan performa terbaik dengan nilai AUC, akurasi, F1 score, precision, recall, dan MCC tertinggi di antara semua model. Hal ini menunjukkan bahwa Neural Network sangat andal dalam membedakan kelas dan memberikan prediksi yang konsisten. Disusul oleh Random Forest, Gradient Boosting dan Tree, kedua

model ini juga memiliki performa yang sangat baik dan stabil, dengan nilai metrik yang tinggi dan seimbang, menjadikannya pilihan yang tepat untuk kebutuhan klasifikasi dengan akurasi tinggi. Model SVM memiliki performa cukup baik dengan metrik yang seimbang, namun masih berada di bawah tiga model teratas. Sementara itu, k-Nearest Neighbors (kNN) memberikan hasil menengah, cocok untuk kasus yang lebih sederhana namun kurang optimal untuk data kompleks. Di sisi lain, Logistic Regression dan Naive Bayes menunjukkan performa paling rendah, dengan nilai metrik yang jauh di bawah model lainnya.

Evaluation results for target High							
Model	AUC	CA	F1	Prec	Recall	MCC	
Random Forest	0.950	0.965	0.765	0.861	0.689	0.752	
Logistic Regression	0.842	0.954	0.706	0.750	0.667	0.682	
Gradient Boosting	0.912	0.970	0.800	0.914	0.711	0.791	
kNN	0.951	0.943	0.644	0.667	0.622	0.613	
Neural Network	0.934	0.967	0.763	0.935	0.644	0.761	
SVM	0.932	0.956	0.707	0.784	0.644	0.687	
Naive Bayes	0.848	0.944	0.667	0.667	0.667	0.636	
Tree	0.952	0.969	0.809	0.818	0.800	0.792	

Gambar 7. Hasil Evaluasi Pemodelan terhadap Kelas Kemampuan Adaptasi Tinggi

Evaluation results for target Moderate							
Model	AUC	CA	F1	Prec	Recall	MCC	
Random Forest	0.921	0.831	0.833	0.796	0.873	0.667	
Logistic Regression	0.766	0.717	0.714	0.695	0.735	0.434	
Gradient Boosting	0.902	0.830	0.822	0.828	0.815	0.659	
kNN	0.882	0.772	0.761	0.769	0.754	0.544	
Neural Network	0.938	0.861	0.859	0.841	0.877	0.723	
SVM	0.884	0.804	0.811	0.755	0.877	0.617	
Naive Bayes	0.759	0.689	0.672	0.683	0.662	0.376	
Tree	0.929	0.870	0.862	0.883	0.842	0.741	


Gambar 8. Hasil Evaluasi Pemodelan terhadap Kelas Kemampuan Adaptasi Sedang

Evaluation results for target Low							
Model	AUC	CA	F1	Prec	Recall	MCC	
Random Forest	0.946	0.863	0.837	0.868	0.809	0.720	
Logistic Regression	0.797	0.752	0.709	0.724	0.694	0.493	
Gradient Boosting	0.938	0.859	0.843	0.819	0.868	0.717	
kNN	0.908	0.796	0.770	0.757	0.783	0.588	
Neural Network	0.964	0.894	0.879	0.874	0.885	0.786	
SVM	0.919	0.833	0.794	0.861	0.736	0.661	
Naive Bayes	0.777	0.726	0.690	0.679	0.702	0.445	
Tree	0.944	0.891	0.878	0.855	0.902	0.780	

Gambar 9. Hasil Evaluasi Pemodelan terhadap Kelas Kemampuan Adaptasi Rendah

Berdasarkan hasil evaluasi performa model terhadap tiga kelas target yaitu High, Moderate, dan Low, dapat disimpulkan bahwa secara umum model Neural Network, Random Forest, Gradient Boosting, dan Tree menunjukkan performa terbaik dan paling konsisten di semua kelas. Pada kelas **High**, model Neural Netwok memiliki nilai AUC dan akurasi yang tinggi, masing-masing 0,934 untuk AUC dan 0,967 untuk akurasi. Meskipun F1 score dan MCC tertinggi dicapai oleh algoritme Tree yaitu F1 Score (0,809) dan MCC (0,792), ini menandakan korelasi prediksi yang baik terhadap data sebenarnya. Pada kelas **Moderate**, performa terbaik juga ditunjukkan oleh Neural Network, Tree, Random Forest, dan Gradient Boosting dengan nilai AUC di atas 0,9 dan akurasi di atas 0,82. F1 score, precision, recall, dan MCC juga berada di atas 0,83 dan 0,67 untuk semua metrik, menunjukkan keseimbangan dan keandalan yang baik. Neural Network unggul dari sisi F1 (0,859) dan recall (0,877), yang menandakan kemampuannya yang kuat dalam menangkap data positif di kelas ini. Sementara itu, pada kelas **Low**, model Neural Network tampil paling unggul dengan AUC sebesar 0,964 dan akurasi 0,894. Semua metrik lainnya juga tinggi, termasuk F1 score (0,879), precision (0,874), recall (0,885), dan MCC (0,786).

Secara keseluruhan, **Neural Network** merupakan model yang paling stabil dan unggul pada ketiga kelas target. Selain dilakukan evaluasi pemodelan algoritma, penelitian juga menggunakan tree viewer untuk melihat faktor apa saja yang mempengaruhi adaptasi mahasiswa di masing-masing kategori adaptasi pembelajaran online. Algoritma tree bekerja dengan cara membangun struktur pohon keputusan (decision tree) yang terdiri dari **simpul (node)** dan **cabang (branch)** untuk merepresentasikan proses pengambilan keputusan secara hierarkis. Graf tree yang dihasilkan memungkinkan pengguna untuk memahami dengan jelas bagaimana model membuat keputusan pada setiap cabang dan node. Dengan visualisasi yang terstruktur, pengguna dapat menganalisis jalur pengambilan keputusan, mengevaluasi faktor yang paling berpengaruh terhadap hasil, dan melakukan penyempurnaan model jika diperlukan. Tree yang dihasilkan dapat dilihat pada gambar 11.



Gambar 10. Graf tree dari keseluruhan kelas adaptasi

Gambar 11 menunjukkan bahwa model Decision Tree mampu memprediksi kemampuan adaptasi (Low, Moderate, High) dengan cukup baik, terutama pada

kelas Low dan Moderate. Pada root node, fitur durasi kelas mendominasi, dengan 48,1 % data diprediksi sebagai Moderate, sementara internal nodes yang mengandalkan fitur seperti jenis kelamin, tipe institusi, usia, lokasi, dan kondisi ekonomi. Cabang kiri dari pohon menunjukkan bahwa mahasiswa dengan durasi kelas rendah dan kondisi ekonomi tertentu cenderung diklasifikasikan dalam kategori Low, terlihat dari warna merah tua yang menunjukkan tingkat kepercayaan tinggi pada prediksi tersebut. Sementara itu, cabang tengah dan kanan memanfaatkan fitur seperti tipe pendidikan, Self LMS, IT Student, Location, dan Network Type untuk membedakan mahasiswa dengan tingkat adaptasi Moderate dan High. Warna hijau mendominasi cabang tengah (Moderate), sedangkan warna biru pada cabang paling kanan menunjukkan prediksi untuk kelas High. Secara keseluruhan, model memiliki struktur yang kompleks dengan **169 nodes** dan **85 leaves**.

6. Kesimpulan

Penelitian ini bertujuan untuk mengevaluasi kinerja machine learning dalam memprediksi kemampuan adaptasi mahasiswa pada lingkungan pembelajaran daring. Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan yaitu,

1. Penelitian ini menggunakan data yang berada di tingkat pendidikan tinggi sebanyak 675 data mahasiswa dari 1205 data yang ada pada dataset awal. Penelitian menggunakan bahasa python dan aplikasi data mining yaitu Orange versi 3.8.
2. Penelitian dilakukan menggunakan tujuh algoritma *supervised learning*. Dari ketujuh algoritma yang diterapkan, neural network memperoleh hasil evaluasi kinerja yang paling baik untuk memprediksi tingkat adaptasi mahasiswa baik secara keseluruhan maupun di setiap tingkat adaptasi mahasiswa (rendah, sedang dan tinggi)
3. Performa model neural network mendapatkan akurasi 0,946 secara kelas keseluruhan. Di tingkat adaptasi tinggi, akurasi yang didapatkan sebesar 0,934; di tingkat adaptasi sedang, akurasi yang didapatkan sebesar 0,938; sedangkan di tingkat adaptasi rendah, akurasi yang dihasilkan model adalah 0,964. Selain akurasi, performa kinerja yang digunakan adalah Akurasi, Presisi, Recall, AUC, F1 dan MCC.
4. Peneliti juga menggali faktor yang mempengaruhi tingkat adaptasi mahasiswa menggunakan algoritma decision tree. Faktor yang paling membedakan antar tingkat adaptasi yaitu variabel durasi kelas. Faktor lainnya yaitu faktor jenis kelamin, tipe institusi, usia, lokasi, dan kondisi ekonomi.
5. Dalam penelitian selanjutnya, dapat meningkatkan kinerja model dengan

menggunakan seleksi fitur maupun keseimbangan data. Selain itu, penelitian selanjutnya juga dapat membuat sistem yang berorientasi pada user sehingga user dapat berinteraksi dalam aplikasi.

Daftar Rujukan

- [1] N. Rane, S. Choudhary, and J. Rane, "Education 4.0 and 5.0: Integrating Artificial Intelligence (AI) for Personalized and Adaptive Learning," *SSRN Electron. J.*, no. January, 2023, doi: 10.2139/ssrn.4638365.
- [2] R. Shafique, W. Aljedaani, F. Rustam, E. Lee, A. Mehmood, and G. S. Choi, "Role of Artificial Intelligence in Online Education: A Systematic Mapping Study," *IEEE Access*, vol. 11, pp. 52570–52584, 2023, doi: 10.1109/ACCESS.2023.3278590.
- [3] C. She, Q. Liang, W. Jiang, and Q. Xing, "Learning adaptability facilitates self-regulated learning at school: the chain mediating roles of academic motivation and self-management," *Front. Psychol.*, vol. 14, no. May, pp. 1–9, 2023, doi: 10.3389/fpsyg.2023.1162072.
- [4] M. M. H. Suzan, N. A. Samrin, A. A. Biswas, and M. A. Pramanik, "Students' Adaptability Level Prediction in Online Education using Machine Learning Approaches," *2021 12th Int. Conf. Comput. Commun. Netw. Technol. ICCCNT 2021*, no. July, 2021, doi: 10.1109/ICCCNT51525.2021.9579741.
- [5] M. Sree, J. J. James, A. Shaji, and A. M. Kuruvilla, "Estimation of Learners' Levels of Adaptability in Online Education Using Imbalanced Dataset," *2023 IEEE Int. Conf. Recent Adv. Syst. Sci. Eng.*, pp. 1–7, 2023, doi: 10.1109/rasse60029.2023.10363543.
- [6] Y. Gonca Telli and A. S. Karakose, "Changes in Innovativeness After Covid-19 Pandemic," *UTMS J. Econ.*, vol. 11, no. 2, pp. 161–170, 2020.
- [7] Z. Li et al., "Students' online learning adaptability and their continuous usage intention across different disciplines," *Humanit. Soc. Sci. Commun.*, vol. 10, no. 1, pp. 1–10, 2023, doi: 10.1057/s41599-023-02376-5.
- [8] O. H. T. Lu, A. Y. Q. Huang, J. C. H. Huang, A. J. Q. Lin, H. Ogata, and S. J. H. Yang, "Applying learning analytics for the early prediction of students' academic performance in blended learning," *Educ. Technol. Soc.*, vol. 21, no. 2, pp. 220–232, 2018.
- [9] O. Iparraguirre-Villanueva et al., "Comparison of Predictive Machine Learning Models to Predict the Level of Adaptability of Students in Online Education," *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 4, pp. 494–503, 2023, doi: 10.14569/IJACSA.2023.0140455.
- [10] G. Stankovska, I. Memedi, and S. P. Grncarovska, "Impact of COVID-19 on Higher Education: Challenges and Opportunities," *Bulg. Comp. Educ. Soc.*, vol. 20, pp. 181–188, 2022, [Online]. Available: <https://eric.ed.gov/?id=ED622717>.
- [11] C. Janiesch and K. Heinrich, "Machine learning and deep learning," 2021.
- [12] L. C. Joy and A. Raj, "A Review on Student Placement Chance Prediction," *2019 5th Int. Conf. Adv. Comput. Commun. Syst. ICACCS 2019*, pp. 542–545, 2019, doi: 10.1109/ICACCS.2019.8728505.
- [13] W. Dwi Yuniarti, E. Winarko, and A. Musdholifah, "Data mining for student assessment in e-learning: A survey," *2020 5th Int. Conf. Informatics Comput. ICIC 2020*, 2020, doi: 10.1109/ICIC50835.2020.9288533.
- [14] M. M. H. Suzan, N. A. Samrin, A. A. Biswas, and M. A. Pramanik, "Students' Adaptability Level Prediction in Online Education using Machine Learning Approaches," *2021 12th Int. Conf. Comput. Commun. Netw. Technol. ICCCNT 2021*, pp. 1–7, 2021, doi: 10.1109/ICCCNT51525.2021.9579741.
- [15] M. Shoaib, N. Sayed, J. Singh, J. Shafi, S. Khan, and F. Ali, "AI student success predictor: Enhancing personalized learning in campus management systems," *Comput. Human Behav.*, vol. 158, no. February, p. 108301, 2024, doi: 10.1016/j.chb.2024.108301.
- [16] V. Teslyuk, A. Doroshenko, and D. Savchuk, "Intelligent Methods and Models for Assessing Level of Student Adaptation to Online Learning," *CEUR Workshop Proc.*, vol. 3387, pp. 331–343, 2023.