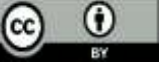




KOMPARASI DECISION TREE, RANDOM FOREST, DAN K-NN MEMPREDIKSI KELULUSAN SISWA MENGGUNAKAN ORANGE

Rafi Rasendriya¹, Fahrian², Aberahamo Onoma Marundrury³, Yakobus Linus Jumadi⁴,
Sumanto⁵, Andi Diah Kuswanto⁶

^{1,2,3,4,5,6} Universitas Bina Sarana Informatika, Bekasi 17411
* Email Korespondensi: rafirasendriya47@gmail.com

INFO ARTIKEL	ABSTRAK
<p>Sejarah Artikel: Diterima Tgl. 09/06/2025 Diperbaiki Tgl. 16/06/2025 Disetujui Tgl. 20/06/2025 Tersedia daring Tgl 27/07/2025</p>	<p>Prediksi kelulusan siswa merupakan salah satu tantangan dalam dunia pendidikan yang memerlukan pendekatan berbasis data. Tidak hanya nilai akhir yang berperan, tetapi juga faktor lain seperti tingkat kehadiran, jam belajar per minggu, nilai ujian sebelumnya, dan aktivitas ekstrakurikuler. Penelitian ini membandingkan kinerja tiga algoritma klasifikasi, yaitu Decision Tree, Random Forest, dan k-Nearest Neighbor (k-NN) dalam memprediksi status kelulusan siswa berdasarkan dataset Student Performance dari Kaggle yang terdiri dari 708 data siswa. Pemodelan dilakukan menggunakan Orange Data Mining dengan pendekatan visual workflow. Evaluasi model dilakukan dengan metode cross-validation sebanyak 20-fold dan diukur menggunakan metrik AUC, akurasi, precision, recall, F1-score, dan MCC. Hasil menunjukkan bahwa algoritma Random Forest memberikan performa terbaik dengan nilai AUC 97,1%, akurasi 94,1%, F1-score 94,2%, precision 94,2%, recall 94,1%, dan MCC 79,7%. Decision Tree dan k-NN juga menunjukkan performa yang cukup baik namun tidak melebihi Random Forest. Temuan ini menunjukkan bahwa Random Forest merupakan model yang paling akurat dan stabil dalam melakukan klasifikasi kelulusan siswa, serta membuktikan bahwa penggunaan Orange Data Mining dapat menjadi alat yang efektif dalam menerapkan teknik data mining di bidang pendidikan.</p>
<p>e-ISSN 2961-9009 p-ISSN 2963-1289</p>	
<p>DOI: https://doi.org/10.58290/jukomtek.v4i2.414</p>	<p>Kata Kunci: Kelulusan Siswa, Data Mining, Klasifikasi, Random Forest, Orange.</p>
<p> ©2022. Diterbitkan oleh Jurnal Komputer dan Teknologi (JUKOMTEK). Artikel ini memiliki akses terbuka di bawah lisensi CC BY (https://creativecommons.org/licenses/by/4.0/)</p>	

PENDAHULUAN

Dalam dunia pendidikan, kelulusan siswa merupakan indikator penting untuk

mengukur keberhasilan proses pembelajaran. Namun, proses penentuan kelulusan masih banyak dilakukan secara manual dan seringkali hanya mempertimbangkan nilai akhir siswa tanpa memperhitungkan faktor lain yang berpengaruh seperti kehadiran, kebiasaan

belajar, dan aktivitas ekstrakurikuler. Pendekatan seperti ini menimbulkan potensi ketidakakuratan dalam pengambilan keputusan akademik.

Seiring dengan meningkatnya ketersediaan data dan kompleksitas variabel yang memengaruhi kelulusan, pemanfaatan teknologi seperti machine learning menjadi semakin relevan. Machine learning menawarkan solusi prediktif berbasis data yang dapat meningkatkan keakuratan dalam klasifikasi kelulusan siswa. Penggunaan algoritma klasifikasi untuk memprediksi kelulusan telah banyak dikaji, namun umumnya hanya berfokus pada satu jenis algoritma tanpa melakukan perbandingan kinerja antar algoritma secara langsung. Selain itu, pemanfaatan platform visual seperti Orange Data Mining masih jarang diterapkan, padahal dapat memberikan kemudahan bagi pengguna dalam membangun dan mengevaluasi model prediksi tanpa memerlukan kemampuan pemrograman tingkat lanjut.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan pendekatan klasifikasi kelulusan siswa berbasis machine learning menggunakan platform Orange. Penelitian ini memfokuskan pada perbandingan kinerja tiga algoritma klasifikasi yang sering digunakan dalam data mining, yaitu Decision Tree, Random Forest, dan k-Nearest Neighbor (k-NN), dalam memprediksi status kelulusan siswa berdasarkan data akademik dan non-akademik. Penelitian ini menyoroti upaya dalam mengidentifikasi sejauh mana ketiga algoritma—Decision Tree, Random Forest, dan k-Nearest Neighbor—mampu memprediksi status kelulusan siswa secara akurat berdasarkan data akademik dan non-akademik. Selain itu, penelitian ini juga mengkaji algoritma mana yang menunjukkan performa paling optimal dalam proses klasifikasi, serta bagaimana kontribusi Orange Data Mining sebagai alat bantu visual dapat memperkuat efisiensi dan efektivitas dalam analisis data pendidikan.

Penentuan kelulusan siswa yang masih mengandalkan pendekatan konvensional tanpa mempertimbangkan berbagai faktor penunjang berpotensi menghasilkan keputusan yang kurang akurat. Untuk itu, diperlukan pemanfaatan algoritma klasifikasi berbasis machine learning seperti Decision Tree, Random Forest, dan k-Nearest Neighbor guna

mengukur akurasi prediksi kelulusan siswa berdasarkan data akademik dan non-akademik. Selain itu, penting untuk mengkaji efektivitas Orange Data Mining sebagai alat bantu visual dalam proses klasifikasi dan analisis data pendidikan.

Adapun tujuan dari penelitian ini adalah untuk membandingkan performa ketiga algoritma dalam memprediksi kelulusan siswa, serta memberikan gambaran mengenai efektivitas Orange Data Mining sebagai alat bantu analisis data. Hasil penelitian ini diharapkan dapat menjadi acuan bagi institusi pendidikan dalam memilih model klasifikasi yang tepat untuk mendukung pengambilan keputusan akademik berbasis data secara lebih obyektif dan efisien.

LANDASAN TEORI

Prediksi

Prediksi adalah proses memperkirakan nilai suatu variabel di masa depan berdasarkan data historis, umumnya berupa data kuantitatif. Tujuannya bukan memberikan hasil pasti, melainkan mendekati kondisi yang mungkin terjadi (Adiguno, Yohanni and Milfa, 2022).

Klasifikasi

Klasifikasi adalah proses mengenali objek atau kelompok berdasarkan prosedur, definisi, dan karakteristik tertentu (Yoggyanto, Maulana and Tri Cahyo, 2024).

Data Mining

Data mining adalah proses otomatis untuk menemukan informasi bernilai dari kumpulan data besar dengan mengidentifikasi pola tersembunyi dan memprediksi kejadian di masa depan. Menurut Witten, data mining berfokus pada pemecahan masalah melalui analisis data dalam basis data (Ananda Mustari *et al.*, 2024).

Machine Learning

Machine Learning (ML) merupakan cabang AI yang digunakan untuk meniru atau menggantikan perilaku manusia dalam menyelesaikan masalah secara otomatis (Nata and Royal, 2022).

Decision Tree

Decision Tree adalah sebuah diagram alir yang berbentuk seperti struktur pohon yang mana setiap internal node menyatakan pengujian

terhadap suatu atribut, setiap cabang menyatakan output dari pengujian tersebut dan leaf node menyatakan kelas-kelas atau distribusi kelas (Rachmat Raharja, Pramudianto and Muchsam, 2024). Algoritma Decision Tree mempunyai kelebihan dan kekurangan. Decision Tree mudah dipahami, mampu menangani data kompleks, dan efektif dalam menentukan atribut penting, namun rentan overfitting dan kurang optimal untuk data tidak seimbang (Muriyatmoko, Musthafa and Wijaya, 2024).

Random Forest

Random Forest adalah algoritma yang membangun sejumlah pohon klasifikasi dan regresi, di mana setiap node dibagi berdasarkan algoritma yang dioptimalkan untuk meminimalkan nilai squared-error loss. Proses pembentukan pohon dalam Random Forest dilakukan dengan cara memilih atribut secara acak dan menggunakan metode CART dalam menyusunnya (Kumala Sari and Randy Suryono, 2024). Berikut adalah keunggulan dan kekurangan Random Forest, Random Forest unggul dalam interpretasi dan kemudahan penggunaan, tetapi dapat mengalami overfitting pada data yang sangat bervariasi (Riansah, Nurdiawan and Herdiana, 2025).

k-Nearest Neighbor (k-NN)

k-Nearest Neighbor (k-NN) adalah suatu metode yang mengimplementasikan algoritma supervised yang dimana hasil dari query instance baru diklasifikasikan berdasarkan paling banyaknya (mayoritas) dari label class pada k-NN (Wasik, Fatah and Munazilin, 2024). Untuk k-NN juga memiliki kelebihan dan kekurangannya, k-NN memiliki pelatihan yang cepat, sederhana, dan tangguh terhadap noise serta data besar, tetapi sensitif terhadap pemilihan nilai k dan memerlukan komputasi yang kompleks (Mujidah and Agustin, 2024).

Orange Data Mining

Orange Data Mining adalah software open source yang berfungsi untuk melakukan analisis data atau data mining, dengan keunggulan utama pada fitur visualisasi dan pemrograman visual. Selain itu, software ini juga mendukung proses klasifikasi data berbasis gambar, sehingga sangat berguna dalam penelitian ini untuk menganalisis dan mengklasifikasikan

gambar (Pranadjaya *et al.*, 2024).

Beberapa penelitian sebelumnya telah membandingkan algoritma klasifikasi dalam memprediksi kelulusan siswa. Penelitian oleh (Muriyatmoko, Musthafa and Wijaya, 2024) menggunakan algoritma Decision Tree C4.5 untuk klasifikasi nilai kelulusan AKPAM dan menunjukkan akurasi sebesar 99,58%. Penelitian lain oleh (Riansah, Nurdiawan and Herdiana, 2025) menunjukkan bahwa algoritma Random Forest memiliki performa lebih tinggi dibandingkan Decision Tree dalam klasifikasi penjualan dengan akurasi 85%. Berdasarkan hasil penelitian (Mujidah and Agustin, 2024), diperoleh kesimpulan bahwa metode KNN telah diuji dengan nilai K sebesar 3, 5, 7, dan 9. Nilai K yang menghasilkan akurasi tertinggi dalam mendeteksi kualitas biji kopi robusta adalah K = 3 dengan akurasi sebesar 92,5% menggunakan 40 citra sebagai sampel uji. Sementara itu, akurasi yang diperoleh pada K = 5 adalah 90%, K = 7 sebesar 86,13%, dan K = 9 sebesar 85%. (Pranadjaya *et al.*, 2024) juga membandingkan performa berbagai algoritma machine learning menggunakan Orange Data Mining untuk klasifikasi jenis kendaraan dan menyimpulkan bahwa platform Orange memudahkan eksplorasi model secara visual. Dalam penelitian tersebut, algoritma Logistic Regression menunjukkan akurasi tertinggi sebesar 98,1%, disusul oleh Neural Network sebesar 96,1%, dan Support Vector Machine sebesar 95,8%, berdasarkan hasil training pada dataset yang digunakan.

Dari studi-studi tersebut, terlihat bahwa algoritma Decision Tree, Random Forest, dan k-NN sering digunakan dalam berbagai kasus klasifikasi. Namun, belum banyak penelitian yang secara langsung membandingkan ketiganya dalam konteks prediksi kelulusan siswa menggunakan Orange Data Mining. Oleh karena itu, penelitian ini bertujuan untuk mengisi celah tersebut.

METODE PENELITIAN

Penelitian ini merupakan penelitian kuantitatif dengan pendekatan eksperimen komparatif, di mana tiga algoritma klasifikasi machine learning dibandingkan kinerjanya dalam memprediksi status kelulusan siswa. Penelitian dilakukan secara eksperimental

menggunakan data sekunder, serta pengujian dan pemodelan dilakukan dengan platform Orange Data Mining.

Data diperoleh secara daring melalui situs Kaggle (<https://www.kaggle.com/datasets/amrmaree/student-performance-prediction>). Kaggle adalah platform terkemuka yang memungkinkan akses ke berbagai jenis dataset untuk penelitian, pembelajaran mesin, dan proyek data science lainnya (Jalil, Homaidi and Fatah, 2024). Karena data bersifat sekunder, tidak dilakukan proses pengumpulan data primer. Data ini telah tersedia dalam format CSV dan diimpor ke dalam Orange Data Mining untuk proses analisis lebih lanjut.

Pra-Pemrosesan Data

Tahap awal penelitian ini adalah pra-pemrosesan data. Data dari Kaggle dibersihkan dengan menghapus atribut yang tidak relevan seperti Name dan Student ID, serta mempertahankan atribut penting seperti Attendance Rate, Study Hours, dan Previous Grade. Atribut Final Grade dikategorikan menjadi dua kelas: *Lulus* (>65) dan *Tidak Lulus* (≤65). Selanjutnya, data dinormalisasi agar semua fitur berada pada skala yang sebanding menggunakan metode standardization.

Pembangunan Model

Model klasifikasi ini dibangun menggunakan tiga algoritma: Decision Tree, Random Forest, dan k-NN. Pemodelan dilakukan melalui *Orange Data Mining* dengan alur kerja visual, mulai dari pemilihan fitur, penetapan target, hingga pelatihan model.

Evaluasi Model

Evaluasi dilakukan menggunakan metode *20-fold cross-validation* untuk menguji performa model secara menyeluruh. Metrik yang digunakan meliputi AUC, akurasi, precision, recall, F1-score, dan MCC. Selain itu, *Confusion Matrix* digunakan untuk melihat ketepatan prediksi terhadap kelas *Lulus* dan *Tidak Lulus*.

HASIL DAN PEMBAHASAN

Berdasarkan hasil evaluasi, model dilakukan dengan metode *Cross Validation 20-fold* menggunakan pengaturan stratified untuk

menjaga keseimbangan distribusi kelas. Tiga algoritma yang diuji adalah Decision Tree, Random Forest, dan k-NN. Hasil evaluasi menunjukkan bahwa Random Forest unggul dengan AUC 97,1%, akurasi 94,1%, F1-score 94,2%, precision 94,2%, recall 0,941, dan MCC 79,7%. Dibandingkan dua algoritma lainnya, Random Forest menunjukkan performa paling andal, akurat, dan stabil, sehingga dipilih sebagai model terbaik dalam penelitian ini.

No	Final Exam Score	Student ID	Study Hours per Week	Attendance Rate	Past Exam Scores
1	63	S147	31	68.2678	86
2	50	S136	16	78.2229	73
3	55	S209	21	87.5251	74
4	65	S458	27	92.0765	99
5	70	S078	37	98.6555	63
6	61	S417	30	84.1592	77
7	61	S302	24	89.3895	95
8	50	S009	31	50.6836	78
9	65	S044	34	80.8632	94
10	55	S331	27	65.4968	86
11	57	S451	35	69.8325	58
12	62	S059	11	92.1046	95
13	59	S315	25	78.8816	81
14	50	S295	18	66.6073	64
15	50	S141	12	62.2177	62
16	50	S274	34	55.0397	71
17	77	S327	32	93.0316	78
18	56	S413	24	71.0852	81
19	58	S452	37	97.7043	55
20	57	S386	39	85.1973	62
21	65	S458	27	92.0765	99
22	55	S079	14	80.0968	79
23	65	S375	36	97.2205	93
24	57	S384	27	93.8222	57
25	62	S207	20	89.0757	92
26	50	S071	26	70.015	69
27	64	S489	27	99.0288	85
28	71	S066	38	78.9825	96
29	58	S018	32	68.8925	66
30	50	S015	27	79.2575	67
31	50	S155	39	50.9121	52
32	61	S159	14	78.7999	91

Gambar 1. Dataset Student Performance

Gambar 1 menunjukkan kolom-kolom yang berisikan kumpulan data dari nilai-nilai siswa ataupun kehadiran siswa yang dapat digunakan sebagai fitur nantinya di software orange. Total keseluruhan data yang ada di dalam Dataset Student Performance berjumlah 708 data siswa.

Berikut adalah isi dan keterangan dari Dataset Student Performance:

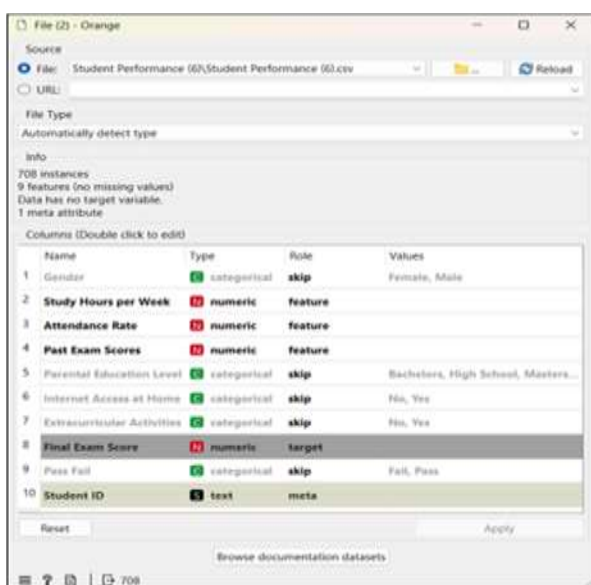
Tabel 1. Deskripsi Dataset Student Performance

No	Atribut	Tipe Data	Deskripsi
1	Final Exam Score	Numerik	Nilai akhir siswa (Atribut Target)
2	Student ID	Teks	ID siswa
3	Study Hours per Week	Numerik	Jumlah jam belajar siswa per minggu
4	Attendance Rate	Numerik	Persentase kehadiran
5	Past Exam Score	Numerik	Nilai siswa pada ujian sebelumnya

Tabel 1 menunjukkan deskripsi dari masing-masing kolom yang ada di dalam Dataset Student Performance. Dalam penelitian kali ini atribut target adalah Final Exam Score dengan mengkategorikan menjadi dua kelas, yaitu: Lulus > 65 dan Tidak Lulus < 65.

Dataset sebanyak 708 data dievaluasi menggunakan metode Cross Validation 20-fold untuk mengukur kinerja model pada data yang belum pernah digunakan sebelumnya. Meskipun akurasi bisa lebih rendah, metode ini memberikan gambaran yang lebih realistis dan mengurangi risiko overfitting, terutama dengan jumlah data yang terbatas. Evaluasi dilakukan melalui widget Test & Score dengan metrik AUC, akurasi (CA), F1-score, precision, recall, dan MCC. Model juga dianalisis menggunakan Confusion Matrix untuk melihat ketepatan klasifikasi, serta Box Plot untuk memahami distribusi fitur terhadap label “Lulus” atau “Tidak Lulus”.

Berikut adalah alur workflow dalam Orange Data Mining. Alur workflow yang digunakan dalam penelitian ini dimulai dari pengimporan file Dataset Student Performance menggunakan widget paling pertama yaitu File. Di dalam widget File dipilih beberapa atribut yang akan digunakan dan diabaikan nantinya dalam penelitian ini. Pada penelitian kali ini, atribut target yang digunakan adalah *Final Exam Score* dan sisanya dirubah menjadi feature dan ada juga yang di skip atau ignore karena tidak dibutuhkan dalam penelitian ini (*Gender* dan *Parental Support*).



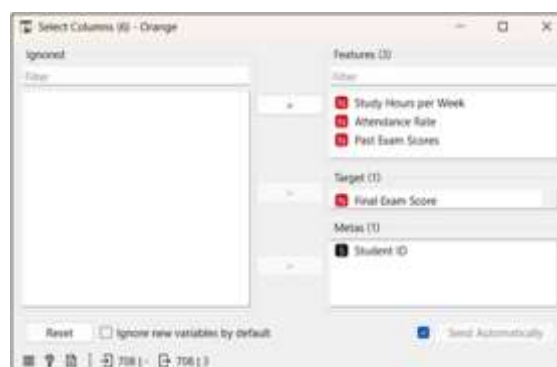
Gambar 2. Widget File

Widget yang digunakan setelah widget File adalah *Data Table* yang dimana berfungsi untuk melihat Data dalam bentuk Tabel.



Gambar 3. Widget Data Table

Setelah widget Data Table yaitu widget Select Column yang berfungsi untuk memisahkan kolom-kolom yang akan digunakan sebagai fitur juga target, pada penelitian ini atribut targetnya adalah kolom Final Exam Score. Pada penelitian ini menggunakan 3 widget Select Column, Select Column yang pertama dan kedua akan membuat dua jalur sebagai pemisah antara target Final Exam Score yang Lulus dan Tidak Lulus.



Gambar 4. Widget Select Column

Pada widget Select Column, terdapat 5 atribut yang sudah dipisahkan, yaitu:

- Student ID: Metas
- Study Hours Per Week: Features
- Attendance Rate: Features
- Past Exam Scores: Features
- Final Exam Score: Target

Penjelasan singkat mengenai masing-masing bagian pada widget Select Column di

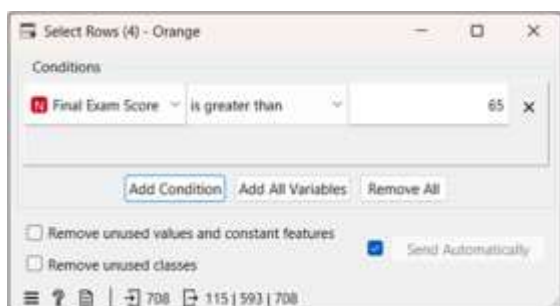
Orange:

- Ignored: Kolom di sini tidak akan digunakan sama sekali dalam pemodelan, baik sebagai input maupun output.
- Features: Fungsi dari Features ini adalah variabel input (fitur) yang akan digunakan sebagai model untuk dipelajari dan dibuat prediksinya.
- Target: Target adalah label atau output yang ingin diprediksi oleh model.
- Metas: Metas hanya sebagai informasi tambahan dan tidak digunakan dalam proses pemodelan.

Setelah widget Select Column ada widget Select Rows yang dimana pada penelitian ini berfungsi untuk memilih atribut Final Exam Score dengan kondisi:

- Final Exam Score diatas 65 = Lulus
- Final Exam Score dibawah 65 = Tidak Lulus

Widget Select Rows pada penelitian ini hampir sama seperti widget Select Column yaitu membuat dua jalur yang berbeda dengan fungsi yang berbeda juga, salah satunya yaitu untuk membedakan kondisi *Final Exam Score* “Lulus” dan “Tidak Lulus”.



Gambar 5. Widget Select Rows Pertama

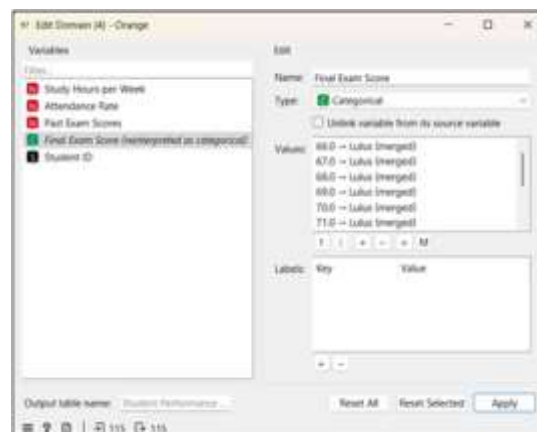


Gambar 6. Widget Select Rows Pertama

Lalu setelah widget Select Rows terdapat widget Edit Domain yang berfungsi pada penelitian ini untuk merubah tipe data Final Exam Score dari Numeric ke Categorical

dan merubah label nilai dari kolom nilai Final Exam Score dengan kondisi yang hampir sama seperti di Select Rows, yaitu:

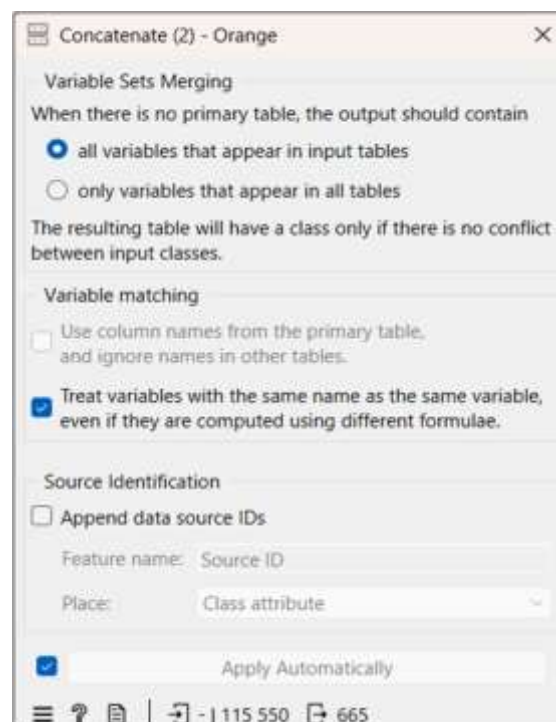
- Lulus > 65
- Tidak Lulus < 65



Gambar 7. Widget Edit Domain

Widget Edit Domain pada penelitian ini juga membutuhkan dua jalur yang berbeda, kedua widget Edit Domain tersebut memiliki jalur masing masing dengan pengaturan yang sedikit berbeda yaitu *Final Exam Score* dengan kondisi diatas 65 dan dibawah 65.

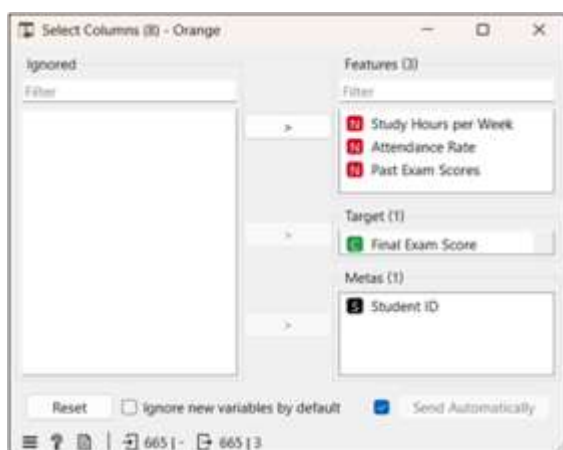
Setelah widget Edit Domain yaitu ada widget Concatenate.



Gambar 8. Widget Concatenate


Widget Concatenate ini berfungsi untuk menggabungkan dua atau lebih dataset menjadi satu. Cocok untuk penelitian kali ini yang mempunyai dua kondisi yang berbeda yaitu Lulus dan Tidak Lulus.

Setelah widget Concatenate, penelitian ini dilanjutkan menggunakan Select Column yang ketiga dengan fungsi memilih atribut Final Exam Score yang sudah dirubah menjadi tipe data Categorical sebagai target.



Gambar 9. Widget Select Column Ketiga

Selanjutnya menggunakan widget Preprocessing. Widget ini digunakan untuk membersihkan dan menyiapkan data sebelum dianalisis atau digunakan untuk machine learning. Pada penelitian ini menggunakan Preprocessors yaitu Normalize Features yang berfungsi membantu membuat semua fitur memiliki skala yang sebanding, supaya model machine learning tidak bias terhadap fitur dengan nilai besar. Penelitian ini menggunakan opsi Standardize to $\mu=0$, $\sigma^2=1$ dengan fungsi yaitu mengubah semua fitur menjadi distribusi normal dengan rata-rata 0 dan varians 1.

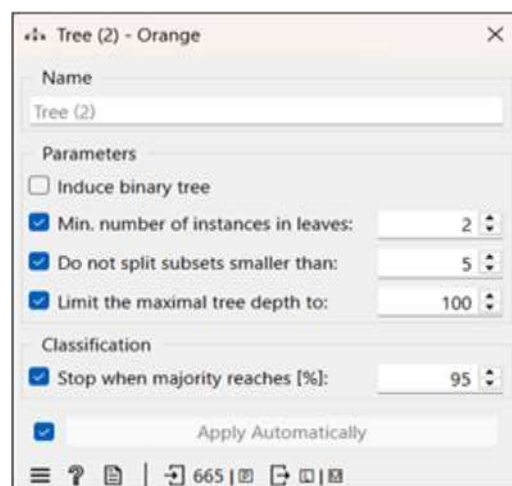


Gambar 10. Widget Preprocessing

Dari widget Preprocessing lanjut ke 3 jalur yang berbeda dan menggunakan widget yang berbeda, yaitu Tree, Random Forest, k-NN dan Test & Score.

Tujuan dari dihubungkannya dari Preprocessing ke Tree, Random Forest, K-NN dan Test & Score adalah:

- Kirim ke Tree, Random Forest dan k-NN untuk pelatihan model
- Kirim ke Test & Score untuk evaluasi performa model.

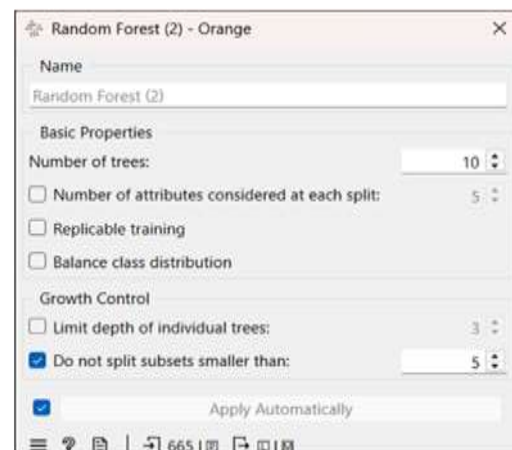


Gambar 11. Widget Tree

Tree (Decision Tree). Fungsi dari widget ini yaitu digunakan untuk membangun model machine learning berbasis pohon keputusan (Decision Tree).

Kegunaan:

- Cocok untuk klasifikasi atau regresi.
- Mudah dipahami dan divisualisasikan.
- Cepat dalam pelatihan dan prediksi.

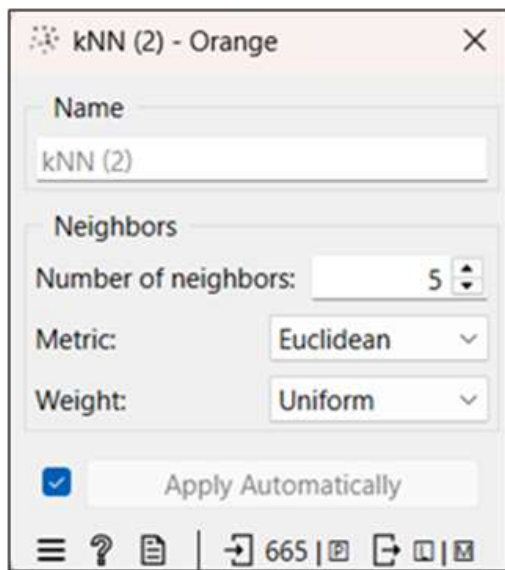


Gambar 12. Widget Random Forest

Random Forest. Widget ini digunakan untuk membangun model machine learning yang memanfaatkan banyak pohon keputusan secara bersamaan.

Kegunaan:

- Cocok untuk masalah klasifikasi dan regresi.
- Lebih akurat karena menggabungkan hasil dari banyak pohon (ensemble).
- Mampu mengurangi risiko overfitting dibandingkan hanya menggunakan satu pohon keputusan.



Gambar 13. Widget k-NN (k-Nearest Neighbor)

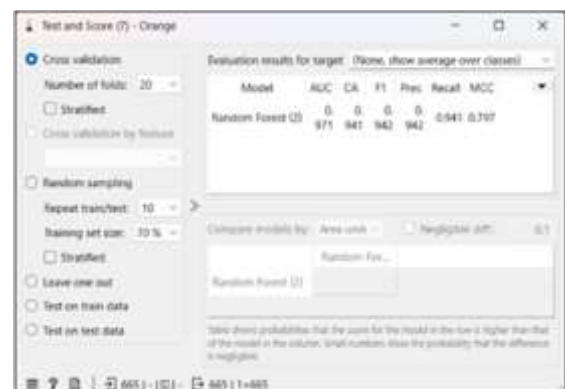
k-Nearest Neighbors (k-NN). Widget ini membangun model machine learning berdasarkan prinsip mencari data terdekat untuk menentukan kelas atau nilai prediksi.

Kegunaan:

- Sederhana dan intuitif, cocok untuk klasifikasi maupun regresi.
- Tidak memerlukan proses pelatihan yang rumit karena langsung menggunakan data training saat prediksi.
- Hasilnya sangat bergantung pada jarak dan jumlah tetangga terdekat yang dipilih (parameter k).



Gambar 14. Widget Test & Score dari Tree



Gambar 15. Widget Test & Score dari Random Forest



Gambar 16. Widget Test & Score dari k-NN

Test & Score. Fungsi dari widget ini yaitu untuk mengevaluasi performa model machine learning. Widget ini akan:

- Melatih model pada sebagian data,
- Mengujinya di data lainnya (misalnya dengan cross-validation),
- Menampilkan metrik evaluasi seperti: AUC, CA, F1, Precision, Recall dan MCC

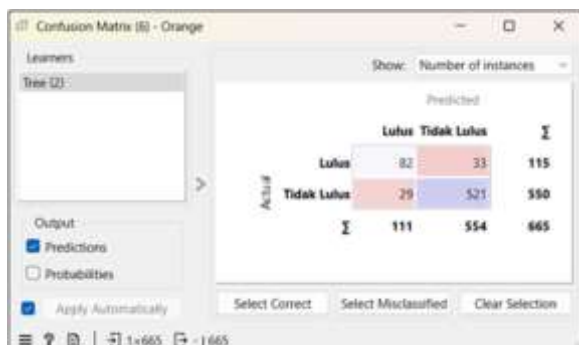
Kegunaan:

- Untuk melihat seberapa baik model memprediksi data.

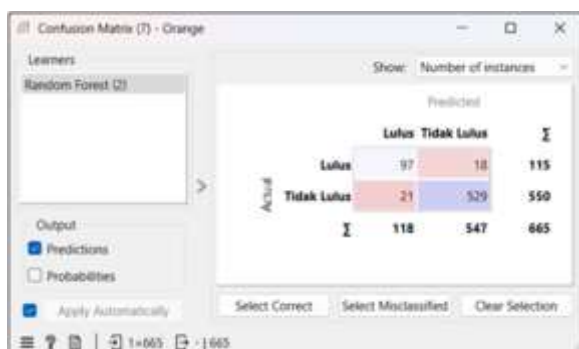
- Membandingkan performa beberapa model sekaligus (jika ada).

Setelah widget Test & Score, penelitian ini menggunakan widget Confusion Matrix. Confusion Matrix adalah tabel yang digunakan untuk mengevaluasi performa model klasifikasi. Tabel ini membandingkan antara:

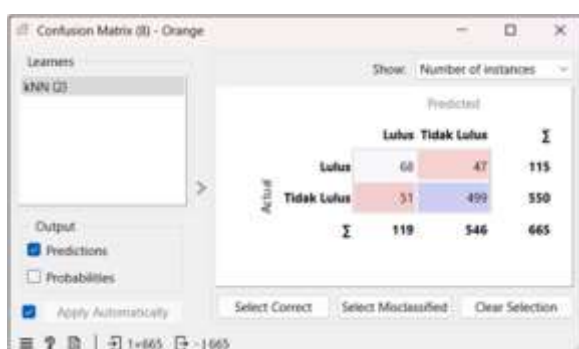
- Label aktual (sebenarnya) dan
- Hasil prediksi dari model.



Gambar 17. Widget Confusion Matrix dari Tree



Gambar 18. Widget Confusion Matrix dari Random Forest



Gambar 19. Widget Confusion Matrix dari k-NN

Pada penelitian terdapat tiga hasil dari Confusion yang berbeda beda, yaitu yang berasal dari widget Tree, Random Forest dan k-NN. Berikut penjelasan dari masing masing

hasil Confusion Matrix.

Tabel 2. Confusion Matrix dari Tree

Confusion Matrix Tree		Prediksi		Total
		Prediksi: Lulus	Prediksi: Tidak Lulus	
Aktual	Aktual: Lulus	82	33	115
	Aktual: Tidak Lulus	29	521	550
Total Prediksi		111	554	665

Interpretasi:

- True Positive (TP): 82
- True Negative (TN): 521
- False Positive (FP): 29
- False Negative (FN): 33

Tabel 3. Confusion Matrix dari Random Forest

Confusion Matrix Random Forest		Prediksi		Total
		Prediksi: Lulus	Prediksi: Tidak Lulus	
Aktual	Aktual: Lulus	97	18	115
	Aktual: Tidak Lulus	21	529	550
Total Prediksi		116	549	665

Interpretasi:

- True Positive (TP): 97
- True Negative (TN): 529
- False Positive (FP): 21
- False Negative (FN): 18

Tabel 4. Confusion Matrix dari k-NN

Confusion Matrix k-NN		Prediksi		Total
		Prediksi: Lulus	Prediksi: Tidak Lulus	
Aktual	Aktual: Lulus	68	47	115
	Aktual: Tidak Lulus	51	499	550
Total Prediksi		119	546	665

Interpretasi:

- True Positive (TP): 68
- True Negative (TN): 499
- False Positive (FP): 51
- False Negative (FN): 47

Penjelasan mengenai TP, TN, FP dan FN:

- True Positive (TP) = Model memprediksi Lulus dan memang benar-benar Lulus.
- True Negative (TN) = Model memprediksi Tidak Lulus dan memang benar-benar Tidak Lulus.
- False Positive (FP) = Model memprediksi Lulus, padahal sebenarnya Tidak Lulus.
- False Negative (FN) = Model memprediksi Tidak Lulus, padahal sebenarnya Lulus.

Dari tampilan ketiga confusion matrix di atas, bisa dilihat kalau setiap model punya tingkat akurasi yang berbeda-beda. Model Decision Tree berhasil memprediksi 82 data ‘Lulus’ dengan benar dan 521 data ‘Tidak Lulus’ dengan benar juga. Sementara itu, Random Forest menunjukkan performa yang lebih baik, karena bisa memprediksi 98 data ‘Lulus’ dan 532 data ‘Tidak Lulus’ dengan tepat. Di sisi lain, model k-Nearest Neighbor (k-NN) punya hasil yang paling rendah, hanya memprediksi 68 data ‘Lulus’ dan 499 data ‘Tidak Lulus’ dengan benar. Jadi, dari ketiga model yang digunakan, Random Forest adalah yang paling akurat dalam mengklasifikasikan data.

Widget yang terakhir digunakan adalah Box Plot. Box Plot digunakan untuk melihat distribusi nilai akhir berdasarkan status kelulusan. Gambar dibawah akan menjelaskan dari ketiga hasil dari algoritma yang sudah digunakan.



Gambar 20. Widget Box Plot dari Tree




Gambar 21. Widget Box Plot dari Random Forest



Gambar 22. Widget Box Plot dari k-NN

Dari ketiga diagram widget Box Plot (Tree, Random Forest dan k-NN) diatas menunjukkan status Tidak Lulus lebih banyak dibanding yang Lulus dari algoritma Tree.

Berikut adalah keseluruhan alur workflow Orange Data Mining untuk memprediksi kelulusan siswa dengan menggunakan algoritma Tree, Random Forest dan k-NN.



Gambar 23. Alur Workflow Orange Data Mining

Dari gambar diatas menunjukkan keseluruhan widget alur workflow untuk memprediksi kelulusan siswa menggunakan algoritma Tree, Random Forest dan k-NN. Terlihat dari awal menggunakan widget File setelah itu dihubungkan ke Data Table lalu dibuat dua jalur yang berbeda dengan kondisi yang berbeda menggunakan widget Select Column, setelah itu dilanjut lagi menggunakan Select Rows > Edit Domain dan digabungkan menjadi satu data menggunakan widget

Concatenate. Setelah itu ada widget Select Column yang ketiga > Preprocessing > dibagi menjadi 3 jalur ke widget Tree, Random Forest, k-NN dan Test & Score lalu dari ketiga jalur tersebut masing masing mempunyai Confusion Matrix dan yang terakhir adalah widget Box Plot.

Tabel 5. Hasil Evaluasi Random Forest

Metrik Evaluasi	Hasil
AUC (Area Under Curve)	97,1%
CA (Classification Accuracy)	94,1%
F1 Score	94,2%
Precision	94,2%
Recall	94,2%
MCC (Matthews Correlation Coefficient)	79,7%

Keterangan Metrik:

- AUC (Area Under Curve): Kemampuan model membedakan kelas.
- CA (Classification Accuracy): Proporsi prediksi benar dari seluruh data.
- Precision: Akurasi model dalam memprediksi kelas “Lulus”.
- F1 Score: Harmonik antara precision dan recall.
- Recall: Kemampuan model menemukan semua siswa yang “Lulus”.
- MCC: Keseimbangan akurasi model terhadap ketidakseimbangan data.

Selanjutnya ada Decision Tree berada di urutan kedua dengan AUC 85,3%, akurasi 90,7%, F1-score 90,6%, dan MCC 67,0%, yang masih menunjukkan performa layak. Sementara itu, k-NN menempati posisi ketiga dengan AUC 92,2%, akurasi 85,3%, F1-score 85,4%, dan MCC 49,2%. Meski AUC-nya cukup tinggi, kinerja keseluruhan k-NN lebih rendah karena sensitivitas terhadap parameter dan distribusi data. Secara keseluruhan, Random Forest merupakan model paling unggul untuk klasifikasi pada dataset ini.

KESIMPULAN

Penelitian ini membuktikan bahwa pendekatan klasifikasi menggunakan machine learning dapat digunakan secara efektif untuk memprediksi kelulusan siswa berdasarkan data akademik dan non-akademik. Dari tiga

algoritma yang diuji—Decision Tree, Random Forest, dan k-NN—diperoleh bahwa Random Forest memiliki performa paling unggul dalam hal akurasi, stabilitas, dan keseimbangan prediksi, menjadikannya model yang paling dapat diandalkan untuk kasus klasifikasi ini. Hasil ini menjawab pertanyaan riset bahwa Random Forest mampu mengatasi keterbatasan data dengan hasil evaluasi tertinggi, sedangkan Decision Tree dan k-NN menunjukkan performa yang cukup baik namun masih berada di bawah Random Forest. Selain itu, pemanfaatan Orange Data Mining terbukti efektif sebagai alat bantu visual untuk eksperimen dan evaluasi model klasifikasi secara praktis dan informatif.

DAFTAR PUSTAKA

- Adiguno, S., Yohanni, S. and Milfa, Y. (2022) ‘Prediksi Peningkatan Omset Penjualan Menggunakan Metode Regresi Linier Berganda’, 1, pp. 275–281.
- Ananda Mustari, K. *et al.* (2024) *IMPLEMENTASI DATA MINING PADA INSTANSI PEMERINTAHAN (SYSTEMATIC LITERATURE REVIEW)*, *Jurnal Mahasiswa Teknik Informatika*.
- Jalil, A., Homaidi, A. and Fatah, Z. (2024) ‘Implementasi Algoritma Support Vector Machine Untuk Klasifikasi Status Stunting Pada Balita’, *G-Tech: Jurnal Teknologi Terapan*, 8(3), pp. 2070–2079. Available at: <https://doi.org/10.33379/gtech.v8i3.4811>.
- Kumala Sari, P. and Randy Suryono, R. (2024) *KOMPARASI ALGORITMA SUPPORT VECTOR MACHINE DAN RANDOM FOREST UNTUK ANALISIS SENTIMEN METAVERSE*.
- Mujidah, M. and Agustin, S. (2024) *KLASIFIKASI KUALITAS BIJI KOPI ROBUSTA MENGGUNAKAN METODE K-NEAREST NEIGHBOR (K-NN) DAN GRAY CO-OCCURANCE MATRIX (GLCM)*, *Jurnal Mahasiswa Teknik Informatika*.
- Muriyatmoko, D., Musthafa, A. and Wijaya, M.H. (2024) *Klasifikasi Profil Kelulusan Nilai AKPAM Dengan Metode Decision Tree C4.5*.

- Nata, A. and Royal, S. (2022) *ANALISIS SISTEM PENDUKUNG KEPUTUSAN DENGAN MODEL KLASIFIKASI BERBASIS MACHINE LEARNING DALAM PENENTUAN PENERIMA PROGRAM INDONESIA PINTAR*, *Journal of Science and Social Research*. Available at: <http://jurnal.goretanpena.com/index.php/JSSR>.
- Pranadjaya, E. *et al.* (2024) *Perbandingan Algoritma Machine Learning menggunakan Orange Data Mining untuk Klasifikasi Jenis Kendaraan pada Sistem Tilang Digital*. Available at: <https://ejournal.atmajaya.ac.id/index.php/JTE>.
- Rachmat Raharja, A., Pramudianto, A. and Muchsam, Y. (2024) *Penerapan Algoritma Decision Tree dalam Klasifikasi Data 'Framingham' Untuk Menunjukkan Risiko Seseorang Terkena Penyakit Jantung dalam 10 Tahun Mendatang*.
- Riansah, A., Nurdiawan, O. and Herdiana, R. (2025) *PENERAPAN ALGORITMA RANDOM FOREST DAN DECISION TREE UNTUK MENINGKATKAN AKURASI KLASIFIKASI PENJUALAN PADA TOKO BANGUNAN*, *Jurnal Mahasiswa Teknik Informatika*.
- Wasik, A., Fatah, Z. and Munazilin, A. (2024) *Prosiding Seminar Nasional Sains dan Teknologi Seri 02 Fakultas Sains dan Teknologi, Universitas Terbuka*.
- Yoggyanto, A., Maulana, A. and Tri Cahyo, D.A. (2024) *Penerapan Metode Convolutional Neural Network (CNN) Dalam Klasifikasi Penyakit Tanaman Jagung*.