
ANALISIS DETEKSI FENOMENA BRAIN ROT PADA MAHASISWA MENGUNAKAN METODE RANDOM FOREST

Feby Wulandari Sembiring¹, Arip Muhridan¹, Mhd. Ihsan Abidi¹,
Irfan Abadi Saragih¹

Universitas Pembangunan Panca Budi, Medan

Email: ¹febywulandari421@gmail.com

Abstract: *The phenomenon of brain rot poses a serious threat to the decline of students' cognitive function due to excessive exposure to low-quality digital content. This study aims to analyze the severity of brain rot and identify the most dominant digital behavioral factors of this phenomenon among students. As a solution to predict the level of risk quantitatively, this study implemented a machine learning approach using the Random Forest Regressor method. Data were collected from 500 student respondents through observation and questionnaires covering variables such as scrolling duration, app switching, GPA, study time, and cognitive symptoms. The test results showed that the model has not achieved optimal performance with an R2-Score of -0.177, RMSE 35.41, and MAE 31.1661. The low accuracy was influenced by inconsistencies in input data units and weak feature correlation in capturing non-linear patterns in the dataset. The study concluded that although scrolling duration was identified as the main influencing factor, the Random Forest model experienced high bias (underfitting). Therefore, hyperparameter optimization and data quality improvement are needed for future use.*

Keywords: *Brainrot; Students; Machine Learning; Random Forest Regressor; Digital Behavior*

Abstrak: Fenomena brainrot (pembusukan otak) menjadi ancaman serius bagi penurunan fungsi kognitif mahasiswa akibat paparan konten digital yang berlebihan dan tidak berkualitas. Penelitian ini bertujuan untuk menganalisis tingkat keparahan brainrot serta mengidentifikasi faktor perilaku digital yang paling mendominasi fenomena tersebut pada kalangan mahasiswa. Sebagai solusi untuk memprediksi tingkat risiko secara kuantitatif, penelitian ini mengimplementasikan pendekatan machine learning dengan metode Random Forest Regressor. Data dikumpulkan dari 500 responden mahasiswa melalui observasi dan kuesioner yang mencakup variabel durasi scrolling, app switching, IPK, lama waktu belajar, dan gejala kognitif. Hasil pengujian menunjukkan bahwa model belum mencapai performa optimal dengan nilai R2-Score sebesar -0,177, RMSE 35,41, dan MAE 31,1661. Rendahnya akurasi dipengaruhi oleh ketidakkonsistenan satuan data input serta korelasi fitur yang kurang kuat dalam menangkap pola non-linear pada dataset. Simpulan penelitian menunjukkan bahwa meskipun durasi scrolling teridentifikasi sebagai faktor pengaruh utama, model Random Forest mengalami high bias (underfitting) sehingga diperlukan optimasi hyperparameter dan penyempurnaan kualitas data untuk penggunaan di masa mendatang..

Kata Kunci: Brainrot; Mahasiswa; Machine Learning; Random Forest Regressor; Perilaku Digital.

PENDAHULUAN

Brainrot (pembusukan otak) merupakan suatu istilah yang merujuk pada penurunan fungsi kognitif otak yang

disebabkan oleh paparan konten digital/gadget yang berlebihan (Azzahra, 2025). Brain rot mengacu pada memburuknya kemampuan intelektual seseorang yang rentan dialami oleh

berbagai kalangan salah satunya kalangan muda yakni mahasiswa. Kerentanan brainrot menyerang kalangan muda (mahasiswa) disebabkan oleh akses konten digital yang tidak berkualitas secara mendominasi. Berdasarkan data dari Badan Pusat Statistik Indonesia, frekuensi akses konten digital pada kalangan muda berusia 16 – 30 tahun sebesar 94,16% dan persentase akses media sosial sebesar 84,28% (Oktavia et al., 2025). Menurut Kementerian Komunikasi dan Digital (KOMDIGI), mahasiswa mendominasi penggunaan konten digital di Indonesia yakni sebesar 93,02% lebih tinggi dibandingkan masyarakat usia lanjut >30 tahun dan anak-anak serta waktu yang dihabiskan mahasiswa untuk akses konten digital antara 6 – 8 jam per hari (Rimalia, 2023). Data dari berbagai sumber tersebut menunjukkan mahasiswa lebih konsumtif terhadap konten digital dan banyak diantaranya secara pasif menonton konten bernilai rendah. Kondisi tersebut berdampak pada otak sehingga berakibat overstimulasi dan overcapacity yang menyebabkan brainrot/pembusukan otak.

Brainrot menjadi masalah serius hingga menarik perhatian internasional sehingga pada tahun 2024 brainrot menjadi topik penelitian di Oxford University. Efek negatif yang ditimbulkan brainrot apabila terus dibiarkan dapat merusak kemampuan kognitif otak dimana mahasiswa mengalami penurunan daya ingat (*short term memory loss*), kesulitan pengambilan keputusan, persepsi realitas yang terdistorsi dan kesulitan berpikir analisis secara mendalam (Saepudin Nirwan, Mohammad Ramadhaniyanto, 2024). Tidak hanya itu, brainrot juga mampu menyebabkan gangguan emosi berupa mudah stress dan cemas, kesulitan mengontrol amarah dan mudah frustrasi, serta cenderung berperilaku impulsif seperti gratifikasi instan (Katadata, 2025). Hal tersebut menyebabkan perubahan perilaku mahasiswa menjadi malas dan kehilangan fokus dalam ranah akademik. Jika hal tersebut dibiarkan berlarut, maka

akan menimbulkan kemerosotan kecerdasan yang secara tidak langsung ini dapat berpengaruh terhadap kualitas generasi muda dan kualitas penerus bangsa ke depannya. Tentunya hal ini perlu untuk segera diambil tindakan penanganan agar brainrot tidak terus-menerus menggerogoti kualitas kecerdasan intelektual mahasiswa.

Namun, fakta di lapangan banyak mahasiswa yang tidak menyadari bahwa mereka telah terkena dampak negatif dari brainrot dan mereka kebingungan terhadap tindakan antisipasi dan rehabilitasi yang perlu dilakukan. Untuk itu diperlukan sebuah sistem yang mampu menganalisis tingkat brain rot pada mahasiswa sehingga dapat diketahui rekomendasi penanganan dampak dari brainrot mengingat universitas royal merupakan kampus berbasis IT yang dimana secara aktivitas mahasiswanya lebih banyak berkecimpung dengan konten digital dan teknologi.

Akan tetapi, sejumlah penelitian terdahulu belum memformulasikan konsep brainrot sebagai topik penelitian yang dapat diukur secara kuantitatif dan diprediksi secara komputasi dengan machine learning. Pendekatan machine learning menggunakan model random forest regressor banyak digunakan dalam penelitian sebetulnya karena kemampuannya dalam menganalisa hubungan non-linear, data multivariat dan memberikan interpretasi melalui feature importance. Oleh karena itu, *state of the art* pada penelitian ini terletak pada implementasi random forest regressor yang menganalisa fenomena brain rot pada mahasiswa berdasarkan integrasi kriteria dari perilaku digital, hasil akademik dan gejala kognitif mahasiswa. Sehingga diharapkan penelitian ini dapat menghasilkan novelty dalam mendefinisikan brain rot dari kriteria tersebut, mengetahui probabilitas brainrot serta interpretasi feature importance sebagai insight faktor dominan dalam fenomena brainrot agar dapat dimanfaatkan sebagai dasar pengambilan keputusan rekomendasi intervensi

Dengan demikian penelitian ini memiliki tujuan untuk menganalisis secara khusus tingkat keparahan dari brain rot yang menyerang mahasiswa dan untuk mengetahui faktor perilaku yang paling mendominasi menciptakan brain rot pada mahasiswa, maka dari itu penelitian ini menggunakan kemajuan teknologi komputer dengan machine learning menggunakan metode random forest regressor. Random forest digunakan dalam penelitian ini karena model tersebut menghasilkan tingkat prediksi yang potensial (Azzahra, 2025), selain itu model tersebut dapat menangani data yang memiliki kompleksitas tinggi serta meminimalisir noise, sehingga dengan keunggulan tersebut model random forest cocok untuk digunakan dalam menganalisis fenomena brain rot pada mahasiswa untuk mengetahui hasil prediksi tingkat keparahan brainrot dari masing-masing mahasiswa.

METODE

Teknik Pengumpulan Data

Teknik pengumpulan data adalah langkah yang digunakan pihak peneliti untuk memperoleh data penunjang dan data pendukung yang dibutuhkan untuk menyelesaikan permasalahan penelitian. Menurut Leedy dan Ornrod (2014) dalam buku “Practical Research : Planning and Design”, Pengumpulan data merupakan prosedur yang digunakan untuk memperoleh informasi dari subjek penelitian melalui tahapan ilmiah yang telah ditetapkan (Nainggolan & Dewantara, 2023). Adapun jenis teknis pengumpulan data dalam penelitian ini sebagai berikut (Mochamad, 2023):

Observasi

Observasi dilakukan dengan mengamati dan mencatat perilaku pengguna secara langsung dan objektif, seperti menghitung durasi harian penggunaan media sosial, frekuensi menonton video pendek (*short-form*

content), hingga perubahan pola fokus saat melakukan aktivitas fisik

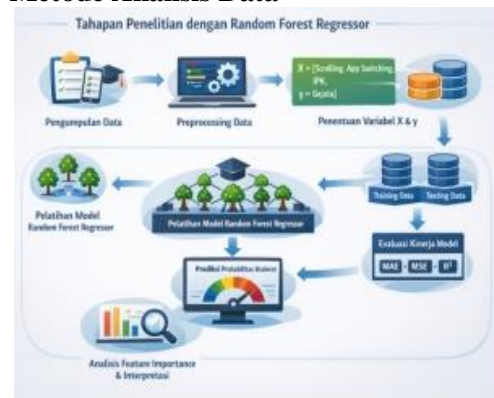
Kuesioner/Angket

Kuesioner atau Angket digunakan untuk menggali aspek subjektif yang tidak terlihat oleh mata, di mana responden diminta mengisi daftar pertanyaan terkait apa yang mereka rasakan, seperti tingkat kecemasan saat jauh dari gawai, kesulitan berkonsentrasi, atau keterikatan emosional terhadap tren internet tertentu. Gabungan data dari hasil pengamatan nyata dan jawaban jujur responden inilah yang nantinya akan disatukan menjadi sebuah dataset mentah untuk diolah lebih lanjut dengan random forest regressor.

Populasi dan Sampel

Populasi adalah Jumlah keseluruhan dari berbagai subjek penelitian. Populasi subjek dalam penelitian ini adalah mahasiswa yang tengah menjalani kegiatan akademik dari mulai semester 1 hingga semester 8 di salah satu Universitas Swasta di Kabupaten Asahan. Dimana jumlah populasi yang dihitung sebagai mahasiswa aktif sampai tahun ajaran 2024-2025 ini adalah ± 2000 mahasiswa. Sampel adalah Sebagian kecil dari populasi total yang secara khusus dipilih guna diteliti untuk mewakili keseluruhan populasi. Penelitian ini direncanakan akan menggunakan sampel sebanyak 500 mahasiswa.

Metode Analisis Data



Gambar 1 Tahapan Analisis Data

Pengumpulan Data

Tahap awal yang dilakukan adalah dengan mengumpulkan data dari kuosioner yang disebarakan kepada mahasiswa dimana kuosioner tersebut mencakup pertanyaan terkait perilaku digital, faktor akademik dan gejala kognitif dimana dari pertanyaan kuosioner diperoleh data dengan kriteria rata – rata durasi scrolling (jam), rata – rata app switching (jumlah aplikasi yang sering dibuka per hari), lama waktu belajar, indeks prestasi kumulatif dan gejala kognitif yang meliputi gejala kognitif (Oktavia et al., 2025).

Data Preprocessing

Data mentah yang diperoleh biasanya masih "kotor". Pada tahap ini, dilakukan pembersihan data (*data cleaning*) untuk menghapus nilai yang hilang atau tidak konsisten. Jika sudah dilakukan pembersihan data, maka akan menghasilkan dataset yang siap untuk diolah datanya (Waruwu et al., 2025).

Penentuan Variabel X dan Y

Variabel independen (X) terdiri dari durasi scrolling, app switching, lama waktu belajar, IPK, dan gejala kognitif, sedangkan variabel dependen (y) berupa nilai probabilitas tingkat brainrot/*brainrot score* yang akan diprediksi oleh model Random Forest Regressor.

Pembagian Data (Training dan Testing)

Dalam penelitian ini menggunakan $test_size = 0.2$ yang artinya splitting data menggunakan rasio 80 : 20, dengan ketentuan 80% data digunakan untuk data training dan 20% untuk data testing. Hal demikian dilakukan agar model dapat mengevaluasi secara objektif dataset yang digunakan

Implementasi Model Random Forest Regressor

Pada tahap ini, model Random Forest Regressor dilatih menggunakan data latih. Model membangun sejumlah pohon keputusan (*decision trees*) dan

menggabungkan hasil prediksinya untuk menghasilkan prediksi nilai probabilitas brainrot yang lebih stabil dan akurat (Ristyawan et al., 2025). Random forest regressor didasarkan pada perataan (rata-rata) prediksi dari kumpulan banyak pohon keputusan (*decision trees*). Berikut merupakan formulasi dari prediksi final untuk input x yang dihitung dengan merata – ratakan hasil prediksi dari semua pohon (Kriswantara & Sadikin, 2022):

$$\hat{y} = \frac{1}{T} \sum_{t=1}^T h_t(x)$$

Keterangan:

\hat{y} : Nilai prediksi

T : Jumlah pohon

$H_t(x)$: prediksi dari pohon ke-t

X : data input (variabel x)

Evaluasi Model Random Forest Regressor

Kinerja model dievaluasi menggunakan metrik regresi seperti Mean Absolute Error (MAE), Mean Squared Error (MSE), dan koefisien determinasi (R^2) untuk menilai tingkat kesalahan dan kemampuan model dalam menjelaskan variasi data (Budiman, 2025).

Klasifikasi Probabilitas Tingkat Brain Rot

Model yang telah dilatih digunakan untuk menghasilkan nilai probabilitas klasifikasi tingkat brainrot dari masing – masing mahasiswa (tinggi, sedang, rendah) yang mencerminkan tingkatan resiko brain rot secara prediktif.

Analisis Feature Importance dan Interpretasi

Tahap akhir dilakukan analisis *feature importance* untuk mengidentifikasi variabel yang paling berpengaruh terhadap tingkat brain rot. Hasil ini digunakan sebagai dasar interpretasi dan rekomendasi dalam konteks akademik maupun sistem pendukung keputusan (Alfajr & Defiyanti, 2024). Fitur yang dipilih antara lain, lama waktu belajar, lama waktu scrolling, lama waktu switching

dan ipk

HASIL DAN PEMBAHASAN

Berdasarkan hasil pengujian model **Random Forest Regressor** menggunakan dataset brainrot mahasiswa, diperoleh hasil evaluasi sebagai berikut:
 RMSE (Root Mean Square Error) = **35.41**
 MAE (Mean Absolute Error) = **31.1661**
 R^2 (Coefficient of Determination) = **-0.177**

Nilai RMSE sebesar 35.41 menunjukkan bahwa rata-rata kesalahan prediksi model terhadap nilai probabilitas brainrot berada pada kisaran ± 35 poin dari nilai aktual. Nilai MAE sebesar 31.1661 mengindikasikan bahwa secara rata-rata, model melakukan kesalahan absolut sekitar 31 poin pada setiap prediksi.

Sementara itu, nilai R^2 sebesar -0.177 menunjukkan bahwa model belum mampu menjelaskan variasi data dengan baik. Nilai R^2 yang negatif mengindikasikan bahwa performa model lebih buruk dibandingkan dengan model sederhana yang hanya menggunakan rata-rata nilai sebagai prediksi.

Dengan demikian, berdasarkan metrik evaluasi yang diperoleh, model Random Forest Regressor pada penelitian ini belum menunjukkan performa prediktif yang optimal dalam mengestimasi probabilitas tingkat brainrot mahasiswa.

Pembahasan

Hasil penelitian menunjukkan bahwa model Random Forest Regressor belum mampu menghasilkan prediksi yang akurat terhadap probabilitas brainrot mahasiswa. Hal ini terlihat dari nilai R^2 yang negatif (-0.177), yang menandakan bahwa variabel-variabel seperti durasi scrolling, app switching, lama belajar, IPK, dan gejala kognitif belum cukup kuat secara kombinitif dalam menjelaskan variasi tingkat brainrot pada dataset yang digunakan.

Tingginya nilai RMSE dan MAE mengindikasikan bahwa terdapat deviasi prediksi yang cukup besar antara nilai aktual dan nilai hasil prediksi model. Beberapa faktor yang dapat mempengaruhi rendahnya performa model antara lain:

- 1). Distribusi data yang tidak merata
- 2). Hubungan non-linear yang kompleks namun tidak cukup tertangkap
- 3). Variabel yang digunakan belum sepenuhnya merepresentasikan fenomena brainrot
- 4). Kemungkinan adanya noise atau outlier dalam dataset

Selain itu, fenomena brainrot merupakan konstruk psikologis dan perilaku yang kompleks, sehingga sulit direpresentasikan hanya dengan indikator kuantitatif seperti durasi penggunaan aplikasi atau IPK. Diperlukan pendekatan variabel tambahan seperti kualitas tidur, tingkat stres, atau validasi instrumen psikometrik untuk meningkatkan akurasi model.

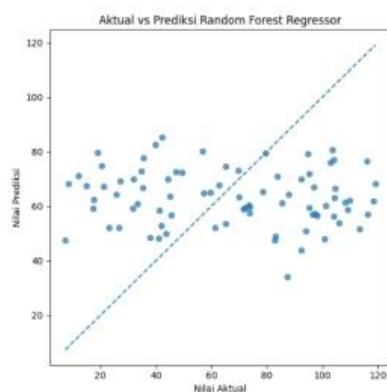
Dengan demikian, hasil ini menunjukkan bahwa meskipun Random Forest secara teori merupakan algoritma yang kuat, performanya sangat bergantung pada kualitas dan relevansi variabel input yang digunakan.

Nilai koefisien determinasi (R^2) yang diperoleh sebesar -0,177 menunjukkan bahwa model Random Forest Regressor belum mampu menjelaskan variasi data probabilitas brainrot dengan baik. Secara matematis, $R^2 = 1 - \frac{SS_{res}}{SS_{tot}}$ $R^2 = 1 - \frac{SS_{res}}{SS_{tot}}$, di mana SS_{res} merupakan jumlah kuadrat error prediksi dan SS_{tot} merupakan total variasi data terhadap rata-ratanya. Nilai R^2 menjadi negatif ketika $SS_{res} > SS_{tot}$, yang berarti kesalahan prediksi model lebih besar dibandingkan jika hanya menggunakan nilai rata-rata sebagai prediksi. Dengan kata lain, model dalam kondisi ini belum berhasil menangkap pola hubungan yang

signifikan antara variabel perilaku digital, akademik, dan gejala kognitif terhadap probabilitas brainrot.

Beberapa faktor dapat menyebabkan kondisi tersebut, di antaranya adalah lemahnya korelasi antar variabel, tingginya noise pada data, distribusi data yang tidak merata, atau kemungkinan bahwa variabel target belum sepenuhnya merepresentasikan konstruk brainrot secara konsisten. Selain itu, apabila nilai probabilitas pada dataset tidak terbentuk dari pola hubungan yang jelas, maka model pembelajaran mesin akan mengalami kesulitan dalam menemukan struktur prediktif yang stabil. Oleh karena itu, performa model sangat bergantung pada kualitas dan relevansi data yang digunakan.

Untuk memperbaiki performa model agar lebih layak dipresentasikan secara akademik, beberapa langkah dapat dilakukan, seperti melakukan penyempurnaan definisi variabel target agar lebih representatif, melakukan tuning hyperparameter pada Random Forest untuk meningkatkan kemampuan generalisasi, serta mempertimbangkan penggunaan pendekatan klasifikasi apabila variabel brainrot lebih tepat direpresentasikan dalam bentuk kategori risiko. Selain itu, validasi silang (cross-validation) dapat diterapkan untuk memperoleh estimasi performa yang lebih stabil dan objektif. Dengan perbaikan tersebut, diharapkan model mampu menghasilkan nilai R^2 yang positif dan memberikan interpretasi yang lebih kuat dalam menjelaskan fenomena brainrot pada mahasiswa.



Gambar 2 Scatter Plot Prediksi

Pada gambar grafik 2 dapat dilihat bahwa terdapat sumbu x yang merujuk pada nilai aktual dan sumbu y merujuk pada nilai prediksi menggunakan random forest regressor. Adapun garis tengah diagonal tersebut merupakan kondisi ideal (kondisi apabila nilai prediksi sejalan dengan nilai aktual). Namun, dari hasil grafik tersebut sebaran titik tidak berpusat pada garis diagonal akan tetapi berkumpul secara horizontal dimana hal ini mengindikasikan terdapat deviasi yang terjadi akibat galat/error yang cukup besar. Titik sebaran dari hasil prediksi nilainya di rentang 40 – 80 sedangkan nilai aktualnya berada direntang 80 – 120 ini tentu menunjukkan model kesulitan memprediksi hasil nilai terlalu tinggi atau terlalu rendah


```
#Feature Importance
import pandas as pd

importance = model.feature_importances_

feat_imp = pd.DataFrame({
    "Faktor": X_test.columns,
    "Pengaruh": importance
}).sort_values(by="Pengaruh", ascending=False)

plt.figure(figsize=(8,5))
plt.barh(
    feat_imp["Faktor"],
    feat_imp["Pengaruh"]
)
plt.gca().invert_yaxis()

plt.xlabel("Importance")
plt.title("Feature Importance Random Forest Regressor")
plt.tight_layout()
plt.show()
```



Gambar 3 Feature Importance

Dari gambar tersebut dapat dilihat bahwa faktor yang menjadi pemicu utama penyebab brainrot yang diprediksi dengan random forest regressor adalah durasi scrolling time sosial media yang bersifat

short content. Akan tetapi faktor penyebab kedua justru lama waktu belajar. Hal ini tentu menjadi galat utama karena kemampuan kognitif otak justru akan meningkat ketika belajar dilakukan dengan baik secara kuantitas maupun kualitas. Dengan demikian dapat diketahui bahwa terdapat kesalahan yang menyebabkan algoritma random forest regressor gagal memprediksi dengan baik tingkat fenomena brainrot pada mahasiswa.

Diagnosa Performa Model (Perspektif Machine Learning)

Dari pola persebaran tersebut, kita dapat mengidentifikasi beberapa masalah teknis utama:

Masalah Underfitting yang Unik:

Meskipun *Random Forest* biasanya rentan terhadap *overfitting* (Samual et al., 2026), grafik ini menunjukkan model gagal menangkap tren linear dari data. Model cenderung memprediksi nilai di sekitar rata-rata (mean), yang merupakan indikasi bahwa fitur (features) yang digunakan mungkin kurang memiliki korelasi kuat dengan target.

Bias Tinggi pada Nilai Ekstrem:

Overestimasi: Pada nilai aktual rendah (< 40), model memprediksi jauh lebih tinggi.

Underestimasi: Pada nilai aktual tinggi (> 80), model memprediksi jauh lebih rendah.

Residu Non-Konstan (Heteroskedastisitas): Varians dari error tidak konsisten di seluruh rentang nilai aktual, yang berarti reliabilitas model berubah-ubah tergantung pada inputnya.

Satuan Data Sebaran Angket Yang Kurang Terstruktur

Setelah kami telaah lebih lanjut untuk mempelajari sumber permasalahan dan tingkat kegagalan algoritma random forest dalam memprediksi dataset, penulis memperoleh temuan dalam penelitiannya dimana terdapat kesalahan dalam mengumpulkan data dimana tidak konsistennya satuan dari data angket masing – masing variabel. Seperti halnya durasi scrolling yang menggunakan satuan jam dan durasi belajar yang

menggunakan satuan menit, perbedaan nilai bilangan tersebut diduga menjadi salah satu penyebab algoritma galat dalam membaca pola data sehingga nilai yang dihasilkan tidak maksimal.

SIMPULAN

Secara teknis, visualisasi tersebut menunjukkan bahwa model *Random Forest* Anda mengalami high bias (underfitting), di mana prediksi cenderung tertahan pada nilai rata-rata (*horizontal banding*) dan gagal menangkap variansi nilai ekstrem pada data aktual. Hal ini mengindikasikan bahwa fitur-fitur input yang digunakan saat ini belum cukup kuat untuk menjelaskan target, atau model memerlukan optimasi *hyperparameter* (seperti *max_depth* dan *n_estimators*) untuk meningkatkan kapasitas belajarnya. Tanpa perbaikan pada kualitas data atau arsitektur model, hasil prediksi ini memiliki tingkat kesalahan (*error*) yang tinggi dan belum reliabel untuk digunakan dalam pengambilan keputusan bisnis atau teknis.

DAFTAR PUSTAKA

- Alfajr, N. H., & Defiyanti, S. (2024). *METODE RANDOM FOREST DAN PENERAPAN PRINCIPAL COMPONENT ANALYSIS (PCA)*. 12(3).
- Azzahra, V. A. (2025). Analisis Prediksi Jumlah Penerimaan Mahasiswa Baru Menggunakan Algoritma Random Forest Regressor. *Data Sciences Indonesia (DSI)*, 5(2), 141–148. <https://doi.org/10.47709/dsi.v5i2.7467>
- Budiman, A. S. (2025). *ANALISIS PREDIKSI KUALITAS UDARA DENGAN METODE RANDOM FOREST BERDASARKAN DATA CUACA*. 824–828.
- Kriswantara, B., & Sadikin, R. (2022). *Used Car Price Prediction with Random Forest Regressor Model*.

- 6(1), 40–49.
<https://doi.org/10.52362/jisicom.v6i1.752>
- Mochamad, N. (2023). Metodologi Penelitian Pendidikan. In *UMSIDA Press*.
- Mohamed, A., Yousef, F., Alshamy, A., Tlili, A., Hosny, A., & Metwally, S. (2025). *Demystifying the New Dilemma of Brain Rot in the Digital Era : A Review. December 2024*.
- Nainggolan, H., & Dewantara, R. (2023). Dampak Promosi Online Serta Mutu Layanan Pengiriman Kepada Loyalitas Konsumen Terhadap Aplikasi Grab. *Journal of Computer Science and Information Technology*, 1(1), 44–58.
<https://doi.org/10.59407/jcsit.v1i1.335>
- Oktavia, F., Rahma, D., Kritis, B., & Kognitif, P. (2025). *Analisis Dampak Brain Rot terhadap Kemampuan Berpikir Kritis Anak berdasarkan Teori Perkembangan Kognitif Piaget*. 4, 1–14.
- Rimalia, W. (2023). Implementation Of Topsis And AHP Methods In Early Detection Of Dental Fever. *Indonesian Journal of Intellectual Publication*, 3(3), 164–171.
- Ristyawan, A., Nugroho, A., & Amarya, T. K. (2025). *Optimasi Preprocessing Model Random Forest Untuk Prediksi Stroke*. 12(1).
- Saepudin Nirwan, Mohammad Ramadhaniyanto, D. H. (2024). *Analisis Komparatif Metode AHP-TOPSIS dan AHP-SAW Dalam Sistem Pendukung Keputusan Untuk Menentukan Siswa Terbaik*. 16(3), 109–119.
- Samual, M. A., Wijanarko, S., & Nasional, U. (2026). *Analisis Perbandingan CNN dan Random Forest dalam Klasifikasi Penyakit Tanaman Jambu Mete Comparative Analysis of CNN and Random Forest for Cashew Plant Disease*. 15, 961–970.
- Waruwu, M., Pu`at, S. N., Utami, P. R., Yanti, E., & Rusydiana, M. (2025). Metode Penelitian Kuantitatif: Konsep, Jenis, Tahapan dan Kelebihan. *Jurnal Ilmiah Profesi Pendidikan*, 10(1), 917–932.
<https://doi.org/10.29303/jipp.v10i1.3057>