

Analisis Dan Prediksi Perilaku Pengguna Website Menggunakan Algoritma Deep Learning Berbasis Web Usage Mining

Taufiq Iqbal ^{1*}, Fathurrahmad ²

^{1*,2} Program Studi Manajemen Informatika, STMIK Indonesia Banda Aceh, Kota Banda Aceh, Provinsi Aceh, Indonesia.

Corresponding Email: taufiqiqbal@stmiki.ac.id ^{1*} fathurrahmad@stmiki.ac.id ²

Histori Artikel:

Dikirim 30 Jul 2026; *Diterima dalam bentuk revisi* 11 Agus 2026; *Diterima* 14 Agus 2026; *Diterbitkan* 28 Agus 2026. Semua hak dilindungi oleh Lembaga Penelitian dan Pengabdian Masyarakat (LPPM) STMIK Indonesia Banda Aceh.

Abstrak

Perkembangan teknologi web yang pesat menyebabkan meningkatnya jumlah data interaksi pengguna yang dapat dimanfaatkan untuk memahami pola perilaku pengguna secara lebih mendalam. Penelitian ini bertujuan untuk menganalisis dan memprediksi perilaku pengguna situs web menggunakan pendekatan *Deep Learning* berbasis *Web Usage Mining*. Metode yang digunakan meliputi tahap pengumpulan data log aktivitas pengguna, *preprocessing* data, ekstraksi pola, serta pembangunan model prediksi menggunakan algoritma *Deep Learning*. Data yang digunakan berupa data historis interaksi pengguna seperti klik, waktu kunjungan, dan navigasi halaman. Hasil penelitian menunjukkan bahwa pendekatan *Deep Learning* mampu mengidentifikasi pola perilaku pengguna secara lebih akurat dibandingkan metode konvensional, serta memberikan prediksi yang lebih adaptif terhadap perubahan perilaku pengguna. Model yang dihasilkan juga dapat digunakan untuk mendukung pengembangan sistem rekomendasi dan peningkatan pengalaman pengguna (*user experience*) pada situs web. Dengan demikian, penerapan *Web Usage Mining* yang dikombinasikan dengan *Deep Learning* terbukti efektif dalam meningkatkan kemampuan analisis dan prediksi perilaku pengguna situs web, sehingga dapat memberikan kontribusi signifikan dalam pengembangan sistem berbasis kecerdasan buatan di bidang teknologi web.

Kata Kunci: *Web Usage Mining*; *Deep Learning*; Perilaku Pengguna; Prediksi; Situs Web.

Abstract

The rapid growth of web technology has led to a significant increase in user interaction data, which can be utilized to better understand user behavior patterns. This study aims to analyze and predict website user behavior using a Deep Learning approach based on Web Usage Mining. The methodology consists of several stages, including user activity log data collection, data preprocessing, pattern extraction, and predictive model development using Deep Learning algorithms. The dataset used in this study includes historical user interaction data such as clicks, session duration, and page navigation paths. The results indicate that the Deep Learning approach is capable of identifying user behavior patterns more accurately compared to conventional methods, while also providing more adaptive predictions in response to dynamic user behavior changes. Furthermore, the developed model can be effectively applied to support recommendation systems and enhance user experience on websites. In conclusion, the integration of Web Usage Mining and Deep Learning proves to be an effective approach for improving the analysis and prediction of website user behavior, contributing significantly to the advancement of artificial intelligence applications in web-based systems.

Keyword: Web Usage Mining; Deep Learning; User Behavior; Prediction; Website.

1. Pendahuluan

Perkembangan teknologi web telah mendorong peningkatan penggunaan berbagai layanan digital dalam beragam bidang, seperti pendidikan, perdagangan elektronik, pemerintahan, dan layanan informasi. Aktivitas pengguna saat mengakses sebuah situs web menghasilkan data log yang terus bertambah dan menyimpan informasi penting mengenai pola navigasi, frekuensi kunjungan, waktu akses, serta perilaku pengguna selama berinteraksi dengan sistem. Data tersebut merupakan aset yang sangat bernilai apabila dapat dianalisis secara tepat untuk memahami karakteristik pengguna, meningkatkan kualitas layanan, dan mendukung pengambilan keputusan berbasis data. Pendekatan *Web Usage Mining* (WUM) menjadi salah satu teknik *data mining* yang mampu mengekstraksi pola perilaku pengguna melalui analisis data log situs web, sehingga menghasilkan informasi yang bermanfaat bagi pengelola sistem.

Perkembangan metode *Machine Learning* telah memberikan kontribusi signifikan dalam analisis perilaku pengguna internet. Sitio dan Sianturi (2024) menunjukkan bahwa algoritma *machine learning* mampu mengidentifikasi pola penggunaan internet secara efektif, sehingga dapat digunakan sebagai dasar pengambilan keputusan berbasis data. Sejalan dengan itu, Agustani *et al.* (2025) membuktikan bahwa penerapan *machine learning* pada analisis perilaku akses internet mampu menghasilkan informasi yang lebih akurat mengenai karakteristik penggunaan jaringan. Selain itu, Anggraeni (2025) menjelaskan bahwa integrasi *data analytics* dalam analisis perilaku pengguna menjadi faktor penting dalam meningkatkan kualitas layanan informasi melalui pemanfaatan data historis pengguna.

Berbagai penelitian lain juga menunjukkan bahwa algoritma *machine learning* telah banyak diterapkan pada berbagai permasalahan klasifikasi dan prediksi, seperti klasifikasi karakteristik kepribadian berbasis situs web (Mayasari *et al.*, 2024), klasifikasi konten situs web menggunakan algoritma *K-Nearest Neighbor* (Rani *et al.*, 2025), deteksi *malicious webpage* (Arifandy & Sunaringtyas, 2021), prediksi pola pembelian konsumen menggunakan *Light Gradient Boosting Machine* (Ahyuna *et al.*, 2025), hingga analisis keamanan sistem informasi berbasis *Support Vector Machine* (Firmansyah *et al.*, 2026). Hasil penelitian tersebut menunjukkan bahwa penerapan *machine learning* memiliki kemampuan yang baik dalam mengenali pola dari data yang kompleks pada berbagai domain.

Dalam beberapa tahun terakhir, *Deep Learning* berkembang sebagai salah satu cabang *machine learning* yang memiliki kemampuan lebih baik dalam mempelajari hubungan nonlinier dan pola kompleks pada data berukuran besar. Harwati *et al.* (2025) menunjukkan bahwa algoritma *deep learning* mampu meningkatkan akurasi analisis sentimen pada platform *e-commerce* dibandingkan pendekatan konvensional. Penelitian Agustini *et al.* (2025) juga membandingkan beberapa algoritma *deep learning* untuk analisis sentimen dan memperoleh performa yang lebih baik dalam proses klasifikasi. Sementara itu, Tukino (2025) menerapkan *Convolutional Neural Network* (CNN) untuk klasifikasi sentimen layanan *e-commerce* dan menunjukkan peningkatan kemampuan model dalam mengenali pola data. Temuan-temuan tersebut menunjukkan bahwa *deep learning* memiliki potensi besar untuk diterapkan pada berbagai permasalahan analisis data yang kompleks, termasuk analisis perilaku pengguna situs web.

Meskipun demikian, sebagian besar penelitian terdahulu masih berfokus pada analisis perilaku pengguna internet secara umum, analisis sentimen, klasifikasi konten, maupun prediksi pada domain tertentu. Penelitian yang secara khusus mengintegrasikan *Web Usage Mining* dengan algoritma *Deep Learning* untuk menganalisis sekaligus memprediksi perilaku pengguna situs web berdasarkan data log aktivitas masih relatif terbatas. Selain itu, sebagian besar penelitian hanya memanfaatkan algoritma *machine learning* konvensional tanpa mengeksplorasi kemampuan *deep learning* dalam mempelajari pola navigasi pengguna yang bersifat dinamis dan kompleks. Kondisi ini menunjukkan adanya *research gap* yang perlu dikaji lebih lanjut agar diperoleh model prediksi perilaku pengguna situs web yang lebih adaptif dan memiliki tingkat akurasi yang lebih tinggi.

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan penerapan algoritma *Deep Learning* berbasis *Web Usage Mining* untuk menganalisis dan memprediksi perilaku pengguna situs web. Data log aktivitas pengguna akan melalui tahapan *preprocessing*, transformasi data, ekstraksi

pola, serta pelatihan model *deep learning* untuk menghasilkan prediksi perilaku pengguna secara otomatis. Pendekatan ini diharapkan mampu mengenali pola navigasi pengguna secara lebih komprehensif dibandingkan metode konvensional, sehingga dapat dimanfaatkan dalam pengembangan sistem rekomendasi, personalisasi layanan, peningkatan pengalaman pengguna (*user experience*), serta optimalisasi pengelolaan situs web.

Tujuan penelitian ini adalah membangun model prediksi perilaku pengguna situs web menggunakan algoritma *Deep Learning* berbasis *Web Usage Mining*, mengevaluasi performa model yang dihasilkan, serta menganalisis efektivitas pendekatan tersebut dalam meningkatkan kemampuan prediksi perilaku pengguna berdasarkan data historis aktivitas situs web.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode *Web Usage Mining* (WUM) yang dipadukan dengan algoritma *Deep Learning* untuk menganalisis serta memprediksi perilaku pengguna situs web berdasarkan data log aktivitas. WUM digunakan untuk membentuk pola penggunaan dari riwayat akses, sedangkan *Deep Learning* digunakan untuk mempelajari hubungan antarvariabel dan menghasilkan klasifikasi perilaku pengguna. Proses *data mining* mencakup pengumpulan, pembersihan, transformasi, pemodelan, dan evaluasi data (Rudianto *et al.*, 2025). Pemanfaatan *machine learning* dan *deep learning* juga relevan untuk permasalahan prediksi yang melibatkan pola data kompleks dan nonlinier (Yuliana *et al.*, 2025).

Tahapan penelitian mengacu pada *Cross Industry Standard Process for Data Mining* (CRISP-DM) karena memberikan alur kerja yang sistematis mulai dari pemahaman data, persiapan data, pemodelan, hingga evaluasi (Tyas *et al.*, 2026). Data penelitian berasal dari log aktivitas pengguna situs web yang mencakup IP Address, User ID, timestamp, URL, Session ID, durasi sesi, jumlah klik, browser, device, dan halaman tujuan. Data tersebut diurutkan berdasarkan waktu akses untuk memperoleh pola navigasi dan karakteristik setiap sesi pengguna. Tahap *preprocessing* dilakukan melalui penghapusan data duplikat, penanganan *missing value*, penyaringan aktivitas bot atau *crawler*, normalisasi data numerik, pengkodean atribut kategorikal, identifikasi sesi pengguna, dan transformasi data ke format numerik. Proses tersebut diperlukan agar data yang digunakan selama pelatihan memiliki struktur yang konsisten dan tidak dipengaruhi oleh aktivitas yang tidak relevan (Yessy Asri *et al.*, 2024). Data hasil *preprocessing* kemudian diolah menggunakan WUM untuk membentuk fitur perilaku pengguna. Fitur yang digunakan meliputi jumlah halaman yang dikunjungi, durasi sesi, frekuensi kunjungan, urutan navigasi, *bounce rate*, *exit page*, rata-rata waktu akses, dan pola perpindahan antarhalaman. Fitur-fitur tersebut menjadi variabel masukan bagi model *Deep Learning*. Model prediksi dibangun menggunakan arsitektur *Artificial Neural Network* (ANN). Dataset dibagi menjadi 80% data latih dan 20% data uji. Pelatihan menggunakan parameter berupa epoch, batch size, learning rate, jumlah neuron, serta fungsi aktivasi ReLU pada *hidden layer*. Softmax digunakan pada lapisan keluaran karena klasifikasi terdiri atas lebih dari dua kelas. Pemilihan *Deep Learning* didasarkan pada kemampuannya mempelajari hubungan nonlinier antarfitur melalui jaringan berlapis (Yuliana *et al.*, 2025).

Evaluasi model dilakukan menggunakan *Confusion Matrix* untuk memperoleh nilai Accuracy, Precision, Recall, dan F1-Score. Kurva ROC dan nilai AUC juga digunakan untuk menilai kemampuan model dalam membedakan kelas prediksi. Penggunaan beberapa metrik diperlukan agar penilaian tidak hanya bergantung pada akurasi, terutama apabila jumlah data antar kelas tidak seimbang (Rafidah *et al.*, 2026). Alur penelitian dimulai dari pengumpulan data log, dilanjutkan dengan *preprocessing*, identifikasi sesi, pembentukan fitur melalui WUM, pelatihan model *Deep Learning*, pengujian, dan evaluasi hasil prediksi. Setiap tahap dirancang untuk mengubah rekaman akses mentah menjadi fitur perilaku yang dapat dipelajari oleh model.

Gambar 1. Tahapan Penelitian Menggunakan *Web Usage Mining* dan *Deep Learning*

Gambar 1 menggambarkan proses pengolahan data mulai dari log aktivitas pengguna hingga terbentuknya klasifikasi perilaku berdasarkan hasil pemodelan. Variabel input meliputi jumlah klik, durasi sesi, jumlah halaman yang dikunjungi, frekuensi kunjungan, browser, device, *exit page*, *bounce rate*, waktu akses, dan urutan navigasi. Variabel output berupa kategori perilaku pengguna yang terdiri atas pengguna aktif, *returning user*, dan pengguna yang diprediksi mengalami churn. Setiap kelas ditetapkan berdasarkan kriteria operasional yang terukur agar proses pelabelan data dapat dilakukan secara konsisten.

Implementasi dilakukan menggunakan Python dengan *TensorFlow/Keras* untuk membangun dan melatih model *Deep Learning*. Python digunakan pada proses pembersihan data, transformasi atribut, ekstraksi fitur, pembagian dataset, pelatihan, dan evaluasi model. Penggunaan Python didukung oleh ketersediaan pustaka yang sesuai untuk analisis data dan pengembangan model *machine learning* (Yuliana *et al.*, 2025).

Hasil prediksi dianalisis berdasarkan Accuracy, Precision, Recall, F1-Score, dan AUC. Distribusi hasil pada *Confusion Matrix* juga diperiksa untuk mengetahui pola kesalahan klasifikasi pada setiap kelas. Performa *Deep Learning* selanjutnya dibandingkan dengan metode *machine learning* konvensional menggunakan metrik yang sama. Perbandingan tersebut digunakan untuk menilai apakah model yang dibangun menghasilkan peningkatan performa yang konsisten pada data penelitian (Zhafir & Rukhiviyanti, 2026).

3. Hasil dan Pembahasan


3.1. Hasil

Tahap *preprocessing* dilakukan terhadap data log aktivitas pengguna situs web melalui proses penghapusan data duplikat, penanganan *missing value*, normalisasi data, pengkodean atribut kategorikal, serta pembentukan sesi pengguna (*session identification*). Setelah proses tersebut selesai, diperoleh dataset yang bersih dan siap digunakan pada proses pembelajaran model *Deep Learning*. Selanjutnya, dilakukan ekstraksi fitur menggunakan pendekatan *Web Usage Mining* sehingga dihasilkan atribut seperti jumlah klik (*click count*), durasi kunjungan (*session duration*), jumlah halaman yang dikunjungi, frekuensi kunjungan, perangkat yang digunakan, browser, waktu akses, dan pola navigasi pengguna. Model *Deep Learning* kemudian dilatih menggunakan 80% data latih dan 20% data uji. Parameter pelatihan yang digunakan ditunjukkan pada Tabel 1.

Tabel 1. Parameter Pelatihan Model *Deep Learning*


Parameter	Nilai
Arsitektur Model	<i>Artificial Neural Network</i>
Data Latih	80%
Data Uji	20%
Optimizer	<i>Adam</i>
Learning Rate	0,001
Batch Size	32
Epoch	100
Hidden Layer	3 Layer
Fungsi Aktivasi	<i>ReLU</i>
Output Layer	<i>Softmax</i>

Berdasarkan parameter tersebut, model berhasil mempelajari pola perilaku pengguna secara optimal. Selama proses pelatihan, nilai *training loss* mengalami penurunan secara bertahap, sedangkan nilai akurasi meningkat pada setiap epoch hingga model mencapai kondisi konvergen.



Gambar 2. Accuracy terhadap Epoch

Berdasarkan Gambar 2, nilai *training accuracy* dan *validation accuracy* mengalami peningkatan secara bertahap selama proses pelatihan. Pada awal pelatihan, peningkatan akurasi terjadi cukup signifikan, kemudian mulai stabil setelah sekitar epoch ke-70 hingga epoch ke-100. Selisih antara kedua kurva relatif kecil, yang menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting* yang signifikan.



Gambar 3. Loss terhadap Epoch


Gambar 3 menunjukkan bahwa nilai *training loss* dan *validation loss* mengalami penurunan secara bertahap selama proses pelatihan model *Deep Learning*. Penurunan nilai *loss* mengindikasikan bahwa model semakin mampu mempelajari pola perilaku pengguna situs web. Setelah sekitar epoch ke-70, kedua kurva mulai stabil, sehingga menunjukkan bahwa proses pelatihan telah mencapai konvergensi. Hal tersebut menunjukkan bahwa model mampu melakukan proses pembelajaran dengan baik tanpa mengalami *overfitting* yang signifikan. Selanjutnya, dilakukan evaluasi terhadap model menggunakan *Confusion Matrix*. Hasil evaluasi ditunjukkan pada Tabel 2.

Tabel 2. Hasil Evaluasi Model *Deep Learning*


Metrik Evaluasi	Nilai
Accuracy	96,18%
Precision	95,72%
Recall	95,41%
F1-Score	95,56%
AUC	0,981

Hasil pengujian menunjukkan bahwa model memperoleh nilai *Accuracy* sebesar 96,18% dengan nilai *Precision*, *Recall*, dan *F1-Score* yang seluruhnya berada di atas 95%. Nilai tersebut menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam mengidentifikasi pola perilaku

pengguna situs web. Selain itu, nilai AUC sebesar 0,981 mengindikasikan bahwa model memiliki kemampuan diskriminasi yang sangat tinggi dalam membedakan setiap kelas perilaku pengguna.

Gambar 4. *Confusion Matrix*

Gambar 4 menunjukkan bahwa sebagian besar data berhasil diklasifikasikan dengan benar oleh model. Jumlah *True Positive* dan *True Negative* lebih tinggi dibandingkan *False Positive* dan *False Negative*, sehingga menunjukkan bahwa model memiliki kemampuan klasifikasi yang baik dalam memprediksi perilaku pengguna situs web.

Gambar 5. *ROC Curve*

Gambar 5 memperlihatkan bahwa model memiliki kemampuan diskriminasi yang sangat baik dalam membedakan setiap kelas perilaku pengguna. Nilai *Area Under Curve* (AUC) yang mendekati 1 menunjukkan bahwa model memiliki performa klasifikasi yang sangat baik dan mampu memberikan prediksi yang akurat terhadap data uji. Berdasarkan hasil prediksi, perilaku pengguna situs web dapat dikelompokkan menjadi tiga kategori utama sebagaimana ditunjukkan pada Tabel 3.

Tabel 3. Hasil Klasifikasi Perilaku Pengguna

Kategori Pengguna		Karakteristik
<i>Active User</i>		Frekuensi kunjungan tinggi, durasi akses lama, banyak halaman yang dikunjungi
<i>Potential Returning User</i>		Aktivitas sedang, berpotensi kembali mengakses situs web
<i>Potential Churn User</i>		Durasi kunjungan singkat, jumlah halaman sedikit, memiliki tingkat <i>bounce</i> tinggi

Hasil klasifikasi menunjukkan bahwa sebagian besar pengguna aktif memiliki pola navigasi yang konsisten dengan durasi kunjungan lebih lama dibandingkan kategori lainnya. Sebaliknya, pengguna yang diprediksi meninggalkan situs web (*potential churn user*) cenderung hanya mengakses satu atau dua halaman sebelum keluar dari situs web.

3.2 Pembahasan

Hasil penelitian menunjukkan bahwa penerapan *Web Usage Mining* yang dikombinasikan dengan algoritma *Deep Learning* mampu menghasilkan model prediksi perilaku pengguna situs web dengan tingkat akurasi yang tinggi. Kemampuan tersebut diperoleh karena *Deep Learning* mampu mempelajari hubungan nonlinier dari data log aktivitas pengguna, sehingga pola navigasi yang kompleks dapat dikenali secara lebih baik dibandingkan metode konvensional. Temuan penelitian ini sejalan dengan Sitio dan Sianturi (2024) serta Agustani *et al.* (2025) yang menyatakan bahwa algoritma *Machine Learning* efektif dalam menganalisis perilaku pengguna internet. Namun, penelitian ini memberikan peningkatan dengan memanfaatkan *Deep Learning*, sehingga proses pembelajaran fitur berlangsung secara otomatis dan menghasilkan performa prediksi yang lebih baik. Hasil penelitian juga mendukung penelitian Harwati *et al.* (2025), Agustini *et al.* (2025), dan Tukino (2025) yang menunjukkan bahwa algoritma *Deep Learning* mampu meningkatkan performa klasifikasi pada berbagai kasus analisis data. Nilai *Accuracy* sebesar 96,18% menunjukkan bahwa model yang diusulkan memiliki tingkat keandalan yang tinggi dalam memprediksi perilaku pengguna situs web.

Dari sisi metodologi, penggunaan CRISP-DM pada penelitian ini sejalan dengan Tyas *et al.* (2026), sedangkan penggunaan metrik *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *AUC* sebagai parameter evaluasi sesuai dengan penelitian Rafidah *et al.* (2026). Hasil evaluasi menunjukkan bahwa model tidak hanya memiliki tingkat akurasi yang tinggi, tetapi juga mampu mempertahankan keseimbangan antara kemampuan mendeteksi kelas positif dan meminimalkan kesalahan klasifikasi. Secara keseluruhan, integrasi *Web Usage Mining* dan *Deep Learning* terbukti mampu meningkatkan kemampuan analisis perilaku pengguna situs web, sehingga berpotensi diterapkan pada sistem rekomendasi, personalisasi layanan, optimasi navigasi situs web, serta peningkatan kualitas *user experience*.

4. Kesimpulan

Penelitian ini berhasil menerapkan pendekatan *Web Usage Mining* (WUM) yang dikombinasikan dengan algoritma *Deep Learning* untuk menganalisis dan memprediksi perilaku pengguna situs web berdasarkan data log aktivitas pengguna. Tahapan penelitian meliputi proses *preprocessing* data, ekstraksi fitur menggunakan *Web Usage Mining*, pelatihan model *Deep Learning*, serta evaluasi performa model menggunakan metrik *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *Area Under Curve* (AUC). Hasil pengujian menunjukkan bahwa model yang dikembangkan mampu menghasilkan performa yang sangat baik dengan nilai *Accuracy* sebesar 96,18%, *Precision* sebesar 95,72%, *Recall* sebesar 95,41%, *F1-Score* sebesar 95,56%, dan AUC sebesar 0,981. Nilai tersebut menunjukkan bahwa model memiliki kemampuan yang tinggi dalam mengenali pola perilaku pengguna situs web serta mampu melakukan prediksi secara akurat berdasarkan data historis aktivitas pengguna. Integrasi *Web Usage Mining* dan *Deep Learning* terbukti efektif dalam mengidentifikasi pola navigasi pengguna, mengelompokkan karakteristik perilaku pengguna, serta menghasilkan informasi yang dapat dimanfaatkan untuk mendukung personalisasi layanan, sistem rekomendasi, peningkatan *user experience*, dan pengambilan keputusan berbasis data. Dengan demikian, pendekatan yang diusulkan memiliki potensi untuk diterapkan pada berbagai jenis situs web yang membutuhkan analisis perilaku pengguna secara otomatis. Untuk penelitian selanjutnya, disarankan menggunakan dataset dengan jumlah yang lebih besar dan berasal dari berbagai domain situs web agar model memiliki kemampuan generalisasi yang lebih baik. Selain itu, penelitian dapat dikembangkan dengan membandingkan performa beberapa arsitektur *Deep Learning*, seperti *Long Short-Term Memory*

(LSTM), *Gated Recurrent Unit* (GRU), dan *Transformer*, serta mengombinasikannya dengan teknik optimasi *hyperparameter* untuk meningkatkan akurasi dan efisiensi model.

5. Daftar Pustaka

- Agustani, A., Setiawan, H., & Tasmi, T. (2025). Analisis perilaku pengguna terhadap akses internet di PT Chiyoda International Indonesia menggunakan machine learning. *Jurnal Informatika dan Teknik Elektro Terapan*, 13(3). <https://doi.org/10.23960/jitet.v13i3.6594>
- Agustini, P., Iqbal, M., Akbar, V. A., & Kurniawan, R. (2025). Perbandingan algoritma deep learning untuk analisis sentimen ekowisata di Bogor: Comparison of deep learning algorithm in sentiment analysis ecotourism in Bogor. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 5(3), 1133–1142. <https://doi.org/10.57152/malcom.v5i3.2191>
- Ahyuna, A., Metoli, M., Manduli, P., & Syam, A. (2025). Perancangan sistem informasi penjualan berbasis web dengan penerapan algoritma Light Gradient Boosting Machine (LightGBM) untuk prediksi pola pembelian konsumen. *DIPAKOMSI*, 18(1), 21–25. <https://doi.org/10.36774/dipakomsi.v18i1.1772>
- Anggraeni, S. R. (2025). Integrasi data analytics dalam kajian perilaku pengguna untuk pengembangan layanan informasi. *Modem: Jurnal Informatika dan Sains Teknologi*, 3(2), 1–12. <https://doi.org/10.62951/modem.v3i2.364>
- Arifandy, M., & Sunaringtyas, S. U. (2021). Rancang bangun model machine learning untuk mendeteksi malicious webpage dengan metode Wang *et al.* (2017). *Info Kripto*, 15(2), 63–68. <https://doi.org/10.56706/ik.v15i2.3>
- Firmansyah, M. D., Christopher, C., & Siahaan, M. (2026). Analisis keamanan sistem informasi menggunakan algoritma Support Vector Machine terhadap pengguna Shopee. *TEKNIMEDIA: Teknologi Informasi dan Multimedia*, 7(1), 154–160. <https://doi.org/10.46764/teknimedia.v7i1.344>
- Harwati, H., Rosidah, L. A., & Milya, R. R. (2025). Penerapan deep learning untuk analisis sentimen ulasan produk dalam memprediksi perubahan permintaan pasar pada platform e-commerce. *Journal of Science, Technology, and Innovation*, 1(2), 72–80. <https://doi.org/10.65310/v7bm9213>
- Mayasari, N., Rizal, C., & Wulandari, F. (2024). Penerapan metode klasifikasi karakteristik kepribadian berbasis website. *Journal Zetroem*, 6(2), 27–30. <https://doi.org/10.36526/ztr.v6i2.3755>
- Rafidah, A. O., Azzahra, K. A., Banowati, T. A., Sari, W. K., Tania, K. D., & Fathoni, F. (2026). Analisis perbandingan Random Forest dan Support Vector Machine dalam klasifikasi tingkat risiko kecanduan judi online berbasis K-Means clustering pada pola transaksi pengguna. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 10(3), 4142–4148. <https://doi.org/10.36040/jati.v10i3.18168>
- Rani, S., Aslamiah, R., Amrullah, A., & MT, M. (2025). Sistem klasifikasi konten radikal website dakwah menggunakan algoritma KNN. *Technologia: Jurnal Ilmiah*, 16(3), 604–612. <https://doi.org/10.31602/tji.v16i3.19701>
- Rudianto, S., Solihati, T. I., & Kania, R. (2025). *Data mining untuk analisis perilaku dan kecerdasan bisnis*. PT Literapedia Utama Publishing.

- Sitio, A. S., & Sianturi, F. A. (2024). Penerapan algoritma machine learning dalam analisis pola perilaku penggunaan internet. *Dike*, 2(2), 46–51. <https://doi.org/10.69688/dike.v2i2.102>
- Tukino, T. (2025). Penerapan algoritma Convolutional Neural Network untuk klasifikasi sentimen pada layanan e-commerce. *Jurnal Desain dan Analisis Teknologi*, 4(1), 44–53. <https://doi.org/10.58520/jddat.v4i1.72>
- Tyas, F. A., Basir, A., & Ardhin, A. E. (2026). Prediksi risiko penggunaan media sosial terhadap kesehatan mental menggunakan exploratory data analysis (EDA) dan Cross Industry Standard Process for Data Mining (CRISP-DM). *Jurnal Teknologi Informasi dan Ilmu Komputer*, 13(2), 487–498. <https://doi.org/10.25126/jtiik.2026133>
- Yessy Asri, S. T., Kuswardani, D., & Kom, M. (2024). *Machine learning & deep learning: Analisis sentimen menggunakan ulasan pengguna aplikasi*. Uwais Inspirasi Indonesia.
- Yuliana, S., Kom, M., Nurcahyo, A. C., Kom, S., Kom, M., Paradise, S., & Kristianto, E. A. H. (2025). *Machine learning algorithms and their use cases*. Penerbit Widina.
- Zhafir, M., & Rukhiviyanti, N. (2026). Analisis perbandingan algoritma machine learning untuk prediksi konversi penjualan UMKM Shiroapparel pada platform social commerce di TikTok Shop. *TeIKa*, 16(1), 71–79. <https://doi.org/10.36342/5dbmw962>