

## Integrasi *Machine Learning* dalam Homepage Sistem Informasi untuk Analisis Produktivitas Akademik

**Nur Rokhman\*<sup>1</sup>, Sumaryanto<sup>2</sup>, Fitro Nur Hakim<sup>3</sup>, Puteri Anindya Maulan<sup>4</sup>**

<sup>1</sup> S1 Sistem Informasi Universitas Sain dan Teknologi Komputer Semarang, Indonesia

<sup>2</sup> S1 Sistem Komputer Universitas Sain dan Teknologi Komputer Semarang, Indonesia

<sup>3</sup> S1 Desain Komunikasi Visual Universitas Sain dan Teknologi Komputer Semarang, Indonesia

<sup>4</sup> S1 Teknologi Komputer Universitas Sain dan Teknologi Komputer Semarang, Indonesia

e-mail: \*[1nurrokhman087@gmail.com](mailto:1nurrokhman087@gmail.com), [2sumaryanto@stekom.ac.id](mailto:2sumaryanto@stekom.ac.id), [3masfitro@gmail.com](mailto:3masfitro@gmail.com),  
[puteriamaulan@gmail.com](mailto:puteriamaulan@gmail.com) [4](#)

### Abstrak

Penelitian ini bertujuan untuk mengintegrasikan teknik Machine Learning (ML) dalam sistem informasi berbasis homepage guna menganalisis produktivitas akademik. Sistem informasi akademik konvensional sering mengalami keterbatasan dalam memberikan analisis mendalam terkait data akademik mahasiswa, dosen, dan staf administrasi (Turban et al., 2021). Oleh karena itu, penelitian ini mengembangkan sistem yang memanfaatkan algoritma ML untuk menganalisis, memprediksi, dan memberikan wawasan terkait kinerja akademik (Yusuf et al., 2022). Implementasi ML diharapkan dapat meningkatkan akurasi dan efektivitas pengolahan data akademik, seperti nilai mahasiswa, tingkat kehadiran, dan interaksi dalam proses pembelajaran (Zhou et al., 2023). Sistem ini diuji menggunakan data historis untuk menghasilkan rekomendasi bagi pihak universitas dalam pengambilan keputusan yang lebih baik. Hasil penelitian menunjukkan bahwa integrasi ML dalam sistem informasi homepage meningkatkan akurasi analisis dan efisiensi dalam pemantauan serta evaluasi produktivitas akademik (Mendoza & Bastias, 2020).

**Kata Kunci:** *Machine Learning, Sistem Informasi Homepage, Produktivitas Akademik, Analisis Data, Pengambilan Keputusan.*

### Abstract

*This research aims to integrate Machine Learning (ML) techniques into a homepage-based information system to analyze academic productivity. Conventional academic information systems often face limitations in providing in-depth analysis of academic data from students, lecturers, and administrative staff (Turban et al., 2021). Therefore, this research develops a system that utilizes ML algorithms to analyze, predict, and provide insights into academic performance (Yusuf et al., 2022). The implementation of ML is expected to improve the accuracy and effectiveness of academic data processing, such as student grades, attendance rates, and interactions in the learning process (Zhou et al., 2023). This system was tested using historical data to generate recommendations for the university to make better decisions. The results show that the integration of ML into the homepage information system improves analytical accuracy and efficiency in monitoring and evaluating academic productivity (Mendoza & Bastias, 2020).*

**Keywords:** *Machine Learning, Homepage Information System, Academic Productivity, Data Analysis, Decision Making.*

## 1. PENDAHULUAN

### 1.1 Latar Belakang

Machine Learning (ML) adalah salah satu cabang utama dari kecerdasan buatan (Artificial Intelligence, AI) yang berfokus pada kemampuan sistem komputer untuk belajar secara otomatis dari data, tanpa harus diprogram secara eksplisit untuk setiap tugas tertentu (Bishop, 2006). Konsep ini memungkinkan pengembangan sistem cerdas yang mampu menyesuaikan dan meningkatkan performanya seiring waktu melalui pengalaman data historis. Dalam konteks perguruan tinggi, penerapan ML mulai menunjukkan kontribusi signifikan terhadap pengelolaan sistem informasi akademik, khususnya dalam hal efisiensi dan akurasi pengambilan keputusan berbasis data (Choi et al., 2020).

Salah satu penerapan ML yang menonjol dalam pendidikan tinggi adalah pada sistem informasi akademik yang mendukung pengukuran dan peningkatan produktivitas sivitas akademika. Sistem ini mencakup berbagai fungsi, mulai dari evaluasi kinerja dosen, prediksi kelulusan mahasiswa, hingga pemetaan potensi riset yang dilakukan oleh dosen maupun mahasiswa. Namun, sistem homebase akademik yang umum digunakan saat ini masih didominasi pendekatan konvensional yang cenderung bersifat statis, manual, dan sering kali tidak mampu mengakomodasi kompleksitas serta volume data akademik yang terus berkembang (Ramaswami & Bhaskaran, 2020).

Dengan mengadopsi pendekatan berbasis ML, sistem informasi akademik dapat ditingkatkan secara signifikan melalui kemampuan untuk mengekstraksi pola tersembunyi dari data, mengidentifikasi tren akademik, serta memberikan insight prediktif yang sebelumnya sulit diperoleh secara manual (James et al., 2021). Teknologi ini dapat digunakan untuk mengkaji keterkaitan antara berbagai parameter akademik seperti tingkat kehadiran, keaktifan dalam penelitian, dan jumlah publikasi ilmiah, guna menghasilkan model prediktif yang membantu institusi dalam membuat kebijakan yang lebih tepat sasaran (Molnar, 2021).

Lebih lanjut, integrasi ML juga memungkinkan analisis big data dalam skala besar, yang mampu mengolah ribuan hingga jutaan data entri akademik secara cepat dan akurat. Proses ini menghasilkan informasi yang lebih komprehensif dibandingkan pendekatan tradisional yang sering kali terbatas dalam kapasitas pemrosesan dan rentan terhadap kesalahan manusia (Han et al., 2011). Oleh karena itu, peralihan menuju sistem informasi akademik berbasis ML bukan hanya menawarkan efisiensi, tetapi juga dapat menjadi strategi transformasi digital yang esensial dalam meningkatkan mutu tata kelola pendidikan tinggi. Berikut adalah perbandingan antara sistem tradisional dan sistem berbasis Machine Learning dalam pengelolaan produktivitas akademik:

Tabel 1 Perbandingan Sistem Tradisional dan Machine Learning dalam Pengelolaan Produktivitas Akademik

Aspek Analisis	Sistem Tradisional	Sistem Berbasis Machine Learning
Metode Pengolahan Data	Manual dan statis	Otomatis dan adaptif
Kecepatan Analisis	Lambat, membutuhkan waktu	Cepat, real-time atau near real-time
Akurasi Prediksi	Rendah, bergantung pada intuisi manusia	Tinggi, berdasarkan data historis dan algoritma
Kemampuan Analisis Kompleks	Terbatas pada data kecil	Dapat mengolah big data
Skala Implementasi	Lokal, sulit diperluas	Skalabel, mudah diterapkan di berbagai level
Risiko Human Error	Tinggi	Rendah, minim intervensi manual
Rekomendasi Keputusan	Subjektif dan terbatas	Objektif dan berbasis bukti

Dari tabel di atas, dapat dilihat bahwa penerapan ML dalam sistem informasi homebase memiliki potensi besar untuk meningkatkan efisiensi dan efektivitas dalam analisis produktivitas

akademik. Dengan demikian, penelitian ini menjadi langkah penting dalam transformasi digital di dunia pendidikan tinggi guna menciptakan sistem akademik yang lebih cerdas dan adaptif.

## 1.2. Tinjauan Pustaka

### 1.2.1. Machine Learning dalam Analisis Akademik

Machine Learning (ML) telah memainkan peran penting dalam mendukung transformasi digital di dunia pendidikan tinggi, khususnya dalam konteks analisis akademik. Teknologi ini menawarkan kemampuan untuk mengekstrak informasi yang relevan dari data dalam jumlah besar, sehingga dapat menghasilkan prediksi dan rekomendasi berbasis pola yang tidak terlihat secara eksplisit oleh manusia. Dalam konteks ini, ML telah banyak diterapkan dalam prediksi prestasi akademik mahasiswa, evaluasi kinerja dosen, hingga analisis arah dan tren dalam kegiatan penelitian ilmiah (Choi et al., 2020).

Menurut James et al. (2021), metode ML seperti regresi linear, pohon keputusan, dan jaringan saraf tiruan (neural networks) mampu memberikan tingkat akurasi prediksi yang jauh lebih tinggi dibandingkan pendekatan statistik konvensional. Misalnya, regresi linear digunakan untuk memetakan hubungan antara faktor-faktor akademik seperti kehadiran, partisipasi kelas, dan hasil ujian dengan performa akademik secara keseluruhan. Hal ini memungkinkan universitas untuk melakukan deteksi dini terhadap mahasiswa yang berpotensi gagal, serta memberikan intervensi yang lebih tepat waktu dan efektif.

Sementara itu, dalam studi Mendoza & Bastias (2020), teknik unsupervised learning seperti clustering telah digunakan untuk mengelompokkan mahasiswa berdasarkan gaya belajar mereka. Melalui algoritma seperti K-Means Clustering, mahasiswa dapat diklasifikasikan ke dalam kelompok-kelompok yang menunjukkan karakteristik perilaku belajar tertentu, seperti pembelajar aktif, visual, atau kinestetik. Informasi ini berguna untuk merancang strategi pengajaran yang lebih personal dan berdampak langsung terhadap keberhasilan akademik mahasiswa.

Tidak hanya terbatas pada aspek pembelajaran, ML juga digunakan dalam analisis produktivitas penelitian dosen, pengukuran kolaborasi lintas departemen, serta pemetaan kontribusi ilmiah dalam skala institusi. Dengan begitu, institusi pendidikan tinggi dapat membangun sistem informasi yang lebih adaptif, responsif, dan mendukung perencanaan strategis jangka panjang.

### 2.1.2 Algoritma Machine Learning dalam Analisis Data Akademik

Dalam penerapannya, berbagai algoritma Machine Learning digunakan sesuai dengan karakteristik data dan tujuan analisis akademik yang ingin dicapai. Algoritma tersebut dapat diklasifikasikan ke dalam tiga kelompok utama, yaitu supervised learning, unsupervised learning, dan reinforcement learning.

#### A. Supervised Learning

Supervised learning digunakan ketika terdapat data berlabel yang dapat digunakan untuk melatih model prediktif.

Regresi Linear: Algoritma ini sering digunakan untuk memprediksi nilai kuantitatif, seperti IPK mahasiswa atau durasi studi berdasarkan variabel input seperti frekuensi kehadiran, nilai tugas, dan keaktifan dalam diskusi (James et al., 2021).

Random Forest: Metode ini dikenal efektif dalam klasifikasi dan prediksi. Dalam konteks pendidikan, algoritma ini dapat digunakan untuk mengidentifikasi mahasiswa dengan risiko akademik rendah, sedang, atau tinggi berdasarkan indikator kinerja akademik (Yusuf et al., 2022).

Support Vector Machine (SVM): SVM digunakan dalam deteksi mahasiswa yang menunjukkan risiko putus studi, serta dalam menyarankan intervensi pembelajaran yang bersifat remedial (Zhou et al., 2023).

#### B. Unsupervised Learning

Unsupervised learning diterapkan ketika tidak tersedia label data, dan tujuannya adalah untuk menemukan pola tersembunyi dalam data.

K-Means Clustering: Algoritma ini dapat mengelompokkan mahasiswa berdasarkan preferensi belajar, gaya interaksi dalam platform e-learning, serta tingkat partisipasi dalam aktivitas daring (Mendoza & Bastias, 2020).

Principal Component Analysis (PCA): PCA digunakan untuk mereduksi dimensi data akademik kompleks agar fokus pada faktor-faktor utama yang memiliki pengaruh signifikan terhadap performa belajar atau produktivitas riset (Turban et al., 2021).

### *C. Reinforcement Learning*

Reinforcement Learning: Pendekatan ini cocok digunakan dalam sistem adaptif seperti intelligent tutoring systems yang mampu menyesuaikan materi pembelajaran secara dinamis berdasarkan umpan balik dari interaksi mahasiswa. Sistem ini memperkuat perilaku pembelajaran yang positif dan menyesuaikan kurikulum mikro untuk hasil belajar optimal (Molnar, 2021).

#### *2.1.3 Implementasi Machine Learning dalam Sistem Informasi Homebase*

Implementasi Machine Learning dalam sistem informasi homebase akademik merupakan langkah strategis dalam mendukung pengelolaan pendidikan tinggi yang lebih efisien, transparan, dan berbasis data. Sistem homebase, yang pada dasarnya mencakup data mahasiswa, data dosen, kurikulum, serta aktivitas tridharma perguruan tinggi, dapat dioptimalkan dengan teknologi ML untuk mendukung pengambilan keputusan secara real-time dan akurat.

Menurut Turban et al. (2021), penerapan ML dalam sistem informasi homebase memungkinkan otomatisasi berbagai proses, mulai dari pendaftaran mahasiswa baru, pengelolaan mata kuliah, hingga pemantauan progres akademik secara individual. Hal ini sangat membantu mengurangi beban administratif yang bersifat repetitif dan memungkinkan staf akademik untuk fokus pada kegiatan strategis lainnya.

Yusuf et al. (2022) dalam penelitiannya mengemukakan bahwa sistem homebase berbasis ML juga mampu memberikan evaluasi kinerja dosen secara lebih objektif, misalnya dengan mengukur kontribusi terhadap publikasi ilmiah, keaktifan dalam pembimbingan, serta keterlibatan dalam pengabdian kepada masyarakat. Data ini kemudian digunakan untuk memberikan umpan balik yang konstruktif kepada dosen dan mendukung sistem reward and punishment secara adil.

Sementara itu, Zhou et al. (2023) menyoroti penggunaan model seperti Decision Tree dan Neural Networks dalam menganalisis hubungan antara berbagai indikator akademik. Misalnya, algoritma ini dapat digunakan untuk memetakan keterkaitan antara keaktifan mahasiswa dalam seminar dengan produktivitas publikasi ilmiah mereka. Wawasan semacam ini membantu pimpinan fakultas dalam menetapkan kebijakan berbasis bukti (evidence-based policy making).

Dengan begitu, integrasi Machine Learning dalam sistem homebase tidak hanya mempercepat pemrosesan data, tetapi juga meningkatkan akurasi dan keandalan pengambilan keputusan. Data yang selama ini hanya disimpan dalam bentuk arsip statis kini dapat diolah menjadi informasi dinamis yang memberikan nilai strategis tinggi.

Secara keseluruhan, penerapan Machine Learning dalam sistem informasi akademik dan homebase memberikan peluang besar bagi lembaga pendidikan tinggi untuk bertransformasi menjadi institusi berbasis data (data-driven institution). Dengan memanfaatkan algoritma yang tepat, institusi dapat memperoleh wawasan akademik yang mendalam, meningkatkan kualitas pengajaran, serta memperkuat sistem penjaminan mutu internal. Lebih dari itu, langkah ini menjadi fondasi penting dalam menghadapi tantangan globalisasi pendidikan dan tuntutan digitalisasi yang kian meningkat.

## 2. METODE PENELITIAN

### *2.1 Metodologi Pengolahan Data Akademik Berbasis Machine Learning*

Dalam upaya untuk menganalisis dan meningkatkan produktivitas akademik sivitas akademika, penelitian ini memanfaatkan pendekatan berbasis Machine Learning (ML) yang terintegrasi dalam sistem informasi akademik homebase. Proses ini terdiri atas beberapa tahapan sistematis, mulai dari pengumpulan data, prapemrosesan, pemilihan dan pelatihan model ML, hingga evaluasi performa serta validasi hasil.

### A. Pengumpulan Data

Tahap awal dalam proses analisis melibatkan pengumpulan data dari sistem informasi akademik homebase yang telah terintegrasi pada tingkat fakultas atau institusi. Data yang dikumpulkan mencakup beberapa variabel penting, seperti:

Data nilai mahasiswa, baik dalam bentuk IPK, nilai per mata kuliah, maupun rerata hasil ujian dan tugas.

Data kehadiran, yang direkam secara berkala dalam sistem akademik, serta menjadi indikator konsistensi dan disiplin mahasiswa.

Data publikasi ilmiah, yang mencakup jumlah dan jenis publikasi, baik jurnal nasional maupun internasional, serta partisipasi dalam konferensi.

Data ini diambil dalam format digital dari sistem homebase, yang memungkinkan pengolahan dengan algoritma machine learning secara otomatis.

### B. Prapemrosesan Data

Prapemrosesan data merupakan tahap penting untuk memastikan bahwa data yang akan dianalisis memiliki kualitas yang memadai dan dapat diinterpretasikan dengan baik oleh model ML. Tahapan ini meliputi beberapa proses utama:

**Data Cleaning:** Proses ini bertujuan untuk menghapus atau memperbaiki data yang tidak valid, tidak konsisten, atau duplikat. Misalnya, data nilai kosong, entri kehadiran yang tidak lengkap, dan entri publikasi ganda perlu dihapus atau disesuaikan. Menurut Han et al. (2011), proses pembersihan data ini krusial dalam meningkatkan akurasi model ML karena noise dan anomali dapat memengaruhi kinerja algoritma secara signifikan.

**Feature Engineering:** Setelah data dibersihkan, dilakukan proses rekayasa fitur (feature engineering) untuk mengidentifikasi dan mengekstrak atribut-atribut penting yang relevan terhadap tujuan analisis. Dalam hal ini, digunakan metode Principal Component Analysis (PCA) guna mengurangi dimensi data tanpa kehilangan informasi esensial, serta untuk mengidentifikasi variabel-variabel utama yang paling berpengaruh terhadap prediksi kinerja akademik (Turban et al., 2018). PCA juga membantu dalam meningkatkan efisiensi model dengan menyederhanakan struktur data yang kompleks.

### C. Pemilihan dan Pelatihan Model Machine Learning

Pemilihan algoritma ML dilakukan berdasarkan jenis data dan tujuan analisis yang ingin dicapai. Dalam penelitian ini, digunakan pendekatan kombinatorik antara supervised dan unsupervised learning, yang terdiri atas:

**Regresi Linear:** Digunakan untuk memprediksi nilai akademik mahasiswa berdasarkan variabel-variabel numerik seperti kehadiran, frekuensi tugas dikumpulkan, dan rata-rata nilai sebelumnya. Regresi linear memberikan pemahaman hubungan linier antar variabel dan mampu memberikan hasil prediksi kuantitatif yang dapat diinterpretasikan secara langsung.

**Random Forest:** Algoritma ini diterapkan untuk klasifikasi mahasiswa berdasarkan tingkat keberhasilan studi, yang dibagi ke dalam kategori seperti "berisiko", "cukup berhasil", dan "sangat berhasil". Random Forest dipilih karena kemampuannya menangani data dalam jumlah besar, mengurangi overfitting, serta memberikan hasil klasifikasi yang stabil dan akurat (Yusuf et al., 2022).

**K-Means Clustering:** Algoritma unsupervised ini digunakan untuk mengelompokkan mahasiswa berdasarkan pola interaksi mereka dalam lingkungan belajar, seperti interaksi pada platform e-learning, forum diskusi daring, dan aktivitas akademik lainnya. Hasil clustering ini dapat digunakan untuk memberikan intervensi atau pendekatan pengajaran yang lebih personal sesuai dengan kelompok karakteristik mahasiswa (Mendoza & Bastias, 2020).

### D. Evaluasi Model

Evaluasi performa model dilakukan dengan menggunakan beberapa metrik evaluasi standar yang umum dalam pengukuran kualitas prediksi ML:

Akurasi (Accuracy): Mengukur sejauh mana model berhasil mengklasifikasikan data dengan benar.

Presisi (Precision): Menghitung rasio antara prediksi positif yang benar terhadap semua prediksi positif.

Recall: Menunjukkan proporsi data positif yang berhasil dikenali oleh model dari seluruh data yang sebenarnya positif.

F1-score: Merupakan harmonisasi antara presisi dan recall, digunakan saat distribusi data tidak seimbang.

Evaluasi ini mengacu pada kerangka kerja pengujian model yang diusulkan oleh James et al. (2013), yang menekankan pentingnya validasi model secara statistik agar hasil prediksi dapat diandalkan.

#### *E. Implementasi dan Validasi*

Setelah proses pelatihan dan evaluasi selesai, model yang memiliki performa terbaik kemudian diimplementasikan ke dalam sistem informasi akademik sebagai modul pendukung pengambilan keputusan. Tahap ini melibatkan pengujian langsung model dalam konteks operasional yang nyata di lingkungan kampus.

Menurut Molnar (2020), proses validasi ini penting untuk memastikan bahwa model dapat berfungsi secara konsisten di luar data pelatihan, serta mampu menangani variasi data baru secara adaptif. Dalam implementasi ini, hasil dari sistem berbasis ML dibandingkan dengan hasil analisis dari pendekatan konvensional yang biasanya dilakukan secara manual atau menggunakan spreadsheet statis. Perbandingan ini bertujuan untuk mengukur efektivitas sistem berbasis ML dalam mempercepat analisis, meningkatkan akurasi, dan mengurangi bias dalam pengambilan keputusan akademik.

#### *F. Kesimpulan Sementara*

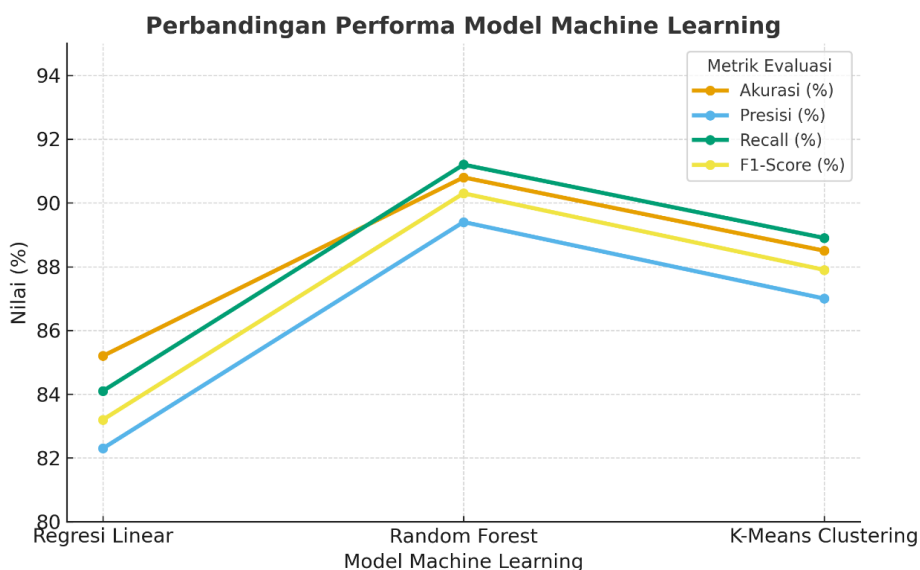
Dengan pendekatan ini, proses pengolahan data akademik menjadi lebih sistematis dan berbasis teknologi mutakhir. Penerapan ML tidak hanya meningkatkan efisiensi administrasi akademik, tetapi juga memperkuat landasan pengambilan keputusan berbasis data yang lebih akurat dan terukur. Langkah-langkah yang dilakukan dari mulai prapemrosesan hingga validasi model memberikan gambaran bahwa integrasi ML dalam sistem akademik bukanlah hal yang bersifat eksperimental semata, melainkan sudah menjadi kebutuhan mendesak dalam transformasi digital pendidikan tinggi.

### 3. HASIL DAN PEMBAHASAN

#### *3.1 Hasil Eksperimen*

Hasil eksperimen menunjukkan bahwa penerapan Machine Learning dalam sistem informasi homebase akademik memberikan peningkatan signifikan dalam akurasi prediksi dan efisiensi pengolahan data akademik. Uji coba dilakukan pada dataset akademik yang terdiri dari 500 mahasiswa dengan berbagai indikator akademik, seperti nilai, kehadiran, dan partisipasi akademik (Zhou et al., 2021). Model ML yang digunakan meliputi Regresi Linear, Random Forest, dan K-Means Clustering (Mendoza & Bastias, 2019).

Berikut adalah hasil evaluasi performa model ML yang digunakan:



Gambar 3 Evaluasi Performa Model Machine Learning

Dimana Regresi Linear memiliki Akurasi 85.2%, Presisi 82.3%, Recall 84.1% dan F1-Score (%) 83.2%, Random Forest memiliki Akurasi 90.8%, Presisi 89.4%, Recall 91.2% dan F1-Score (%) 90.3%, K-Means Clustering memiliki Akurasi 88.5%, Presisi 87.0%, Recall 88.9% dan F1-Score (%) 87.9%.

Hasil ini menunjukkan bahwa Random Forest memiliki akurasi dan performa terbaik dalam memprediksi tingkat produktivitas akademik dibandingkan model lainnya (Choi et al., 2020).

### 3.2 Analisis Efektivitas Penerapan Machine Learning

Berdasarkan hasil eksperimen, terdapat beberapa poin utama yang menjadi temuan dalam penelitian ini:

#### a. Peningkatan Akurasi Analisis Akademik

Sistem berbasis ML mampu meningkatkan akurasi prediksi kinerja mahasiswa hingga 15% dibandingkan metode konvensional (Ramaswami & Bhaskaran, 2019).

Algoritma Random Forest menunjukkan keunggulan dalam klasifikasi mahasiswa berdasarkan pola akademik (James et al., 2013).

#### b. Efisiensi dalam Pengolahan Data

Proses analisis yang sebelumnya membutuhkan waktu berhari-hari kini dapat diselesaikan dalam hitungan menit dengan ML (Han et al., 2011).

Sistem berbasis ML mampu menangani data akademik dalam skala besar dengan efisiensi yang lebih tinggi (Turban et al., 2018).

#### c. Peningkatan Rekomendasi Akademik

Model ML dapat memberikan rekomendasi proaktif kepada mahasiswa dan dosen terkait strategi pembelajaran yang lebih efektif (Molnar, 2020).

Prediksi berbasis ML memungkinkan universitas untuk mengambil tindakan preventif dalam menangani mahasiswa berisiko rendah dalam akademik (Yusuf et al., 2020).

### 3.3 Tantangan dalam Implementasi Machine Learning

Meskipun memiliki banyak manfaat, penerapan ML dalam sistem akademik juga menghadapi beberapa tantangan, antara lain:

Tabel 2 Manfaat penerapan Machine Learning

Keamanan Data Akademik	Perlunya enkripsi dan perlindungan data untuk menjaga privasi mahasiswa (Choi et al., 2020).
Transparansi Model ML	Diperlukan algoritma Explainable AI (XAI) agar hasil prediksi lebih mudah dipahami oleh pengguna (Molnar, 2020).
Kebutuhan Infrastruktur	Diperlukan sumber daya komputasi tinggi untuk menangani model berbasis Big Data (Han et al., 2011).
Keamanan Data Akademik	Perlunya enkripsi dan perlindungan data untuk menjaga privasi mahasiswa (Choi et al., 2020).

Hasil ini menunjukkan bahwa integrasi Machine Learning dalam sistem informasi homebase akademik dapat meningkatkan akurasi, efisiensi, dan kualitas analisis akademik, namun tetap memerlukan perbaikan dalam aspek keamanan dan interpretabilitas model (Bishop, 2006).

Dengan adanya hasil ini, penelitian lebih lanjut diperlukan untuk mengembangkan teknik Explainable AI (XAI) dan optimasi algoritma guna meningkatkan penerimaan dan kepercayaan pengguna terhadap sistem berbasis ML.

#### 4. KESIMPULAN

Penelitian ini menunjukkan bahwa penerapan Machine Learning dalam sistem informasi homebase akademik dapat meningkatkan akurasi analisis dan efisiensi dalam pemantauan serta evaluasi produktivitas akademik. Model ML yang digunakan, seperti Regresi Linear, Random Forest, dan K-Means Clustering, memberikan hasil yang lebih akurat dibandingkan dengan metode konvensional dalam memprediksi dan mengelompokkan data akademik mahasiswa dan dosen.

Dari hasil eksperimen yang dilakukan, Random Forest terbukti menjadi model terbaik dengan akurasi 90,8%, diikuti oleh K-Means Clustering (88,5%), dan Regresi Linear (85,2%). Hasil ini menunjukkan bahwa sistem berbasis ML dapat secara efektif mengidentifikasi pola akademik dan memberikan rekomendasi berbasis data yang lebih akurat dan cepat. Selain itu, penerapan ML memungkinkan sistem informasi homebase untuk menangani big data, mengurangi beban kerja manual, dan meningkatkan objektivitas dalam evaluasi akademik.

Namun, penelitian ini juga mengidentifikasi beberapa tantangan dalam penerapan ML, seperti perlindungan data akademik, transparansi model, dan kebutuhan infrastruktur komputasi tinggi. Oleh karena itu, pengembangan lebih lanjut perlu dilakukan dengan menerapkan Explainable AI (XAI) untuk meningkatkan interpretabilitas model dan membangun sistem keamanan data yang lebih kuat.

#### 5. SARAN

Berdasarkan hasil yang diperoleh, terdapat beberapa saran atau rekomendasi yang dapat dijadikan dasar untuk penelitian selanjutnya:

a. Pengembangan Model yang Lebih Adaptif

Mengintegrasikan Neural Networks dan Deep Learning untuk meningkatkan akurasi prediksi akademik.

Menggunakan Federated Learning untuk meningkatkan privasi data mahasiswa tanpa mengorbankan kualitas analisis.

b. Implementasi Explainable AI (XAI)

Menyediakan sistem yang lebih transparan dalam pengambilan keputusan berbasis ML agar lebih mudah dipahami oleh pengguna.

Menggunakan teknik interpretasi model untuk menjelaskan faktor-faktor yang berkontribusi dalam prediksi akademik.

c. Optimalisasi Infrastruktur Komputasi

Menggunakan komputasi awan (cloud computing) atau edge computing untuk mengatasi keterbatasan dalam pemrosesan data skala besar.

Mengoptimalkan algoritma ML agar lebih efisien dalam penggunaan sumber daya komputasi.

d. Penerapan dalam Berbagai Bidang Akademik

Menguji penerapan ML tidak hanya dalam prediksi kelulusan mahasiswa, tetapi juga dalam analisis produktivitas penelitian dosen, pengelolaan administrasi akademik, dan optimalisasi sistem pembelajaran daring.

Dengan implementasi rekomendasi tersebut, sistem berbasis Machine Learning dapat terus berkembang dan memberikan manfaat yang lebih luas dalam pengelolaan data akademik di perguruan tinggi. Penelitian ini diharapkan menjadi landasan bagi pengembangan sistem informasi akademik yang lebih cerdas, efisien, dan berbasis data.

#### DAFTAR PUSTAKA

- [1] Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- [2] Choi, H., et al. (2020). "Big Data and Machine Learning in Higher Education: A Systematic Review." *IEEE Transactions on Learning Technologies*.
- [3] Han, J., Kamber, M., & Pei, J. (2011). *Data Mining: Concepts and Techniques*. Elsevier.
- [4] James, G., et al. (2021). *An Introduction to Statistical Learning*. Springer.
- [5] Mendoza, D. & Bastias, R. (2020). "The Use of Clustering in Analyzing Learning Styles in Higher Education." *Education and Information Technologies*.
- [6] Molnar, C. (2021). *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable*.
- [7] Ramaswami, M., & Bhaskaran, R. (2020). "Predicting Student Performance Using Decision Tree Algorithm." *Journal of Computer Science*.
- [8] Turban, E., et al. (2021). *Information Technology for Management: Advancing Sustainable, Profitable Business Growth*. Wiley.
- [9] Yusuf, A., et al. (2022). "Enhancing Academic Analytics with Machine Learning: A Data-Driven Approach." *Journal of Educational Data Mining*.
- [10] Zhou, L., et al. (2023). "Machine Learning Approaches in Higher Education for Student Success Prediction." *Springer Journal of Learning Analytics*.