

Analisis Penggunaan Framework dalam Pengembangan Kecerdasan Buatan untuk Meningkatkan Efisiensi dan Akurasi Model

Salsa Billa¹, Junita Lestari², Al Ridho Mahardika³, Rais Affaruq Zunnurain⁴

^{1,2,3} Fakultas Teknologi dan Bisnis, Program Studi Sistem Informasi

⁴ Fakultas Teknologi dan Bisnis, Program Studi Bisnis Digital
Universitas Putra Abadi Langkat

ARTICLE INFO

Article history:

Received: Des 20, 2025

Revised: Jan 12, 2026

Accepted: Jan 24, 2026

Keywords:

Efisiensi dan Akurasi Model;
Framework Kecerdasan Buatan;
PyTorch;
Systematic Literature Review;
TensorFlow.

ABSTRAK

Penelitian ini bertujuan untuk menganalisis secara sistematis penggunaan berbagai framework kecerdasan buatan (AI) dalam meningkatkan efisiensi dan akurasi model. Dengan menggunakan pendekatan Systematic Literature Review (SLR) berdasarkan panduan PRISMA 2020, penelitian ini meninjau 250 artikel dari berbagai basis data bereputasi seperti Scopus, IEEE Xplore, ScienceDirect, dan SpringerLink, dengan 35 artikel memenuhi kriteria inklusi. Hasil analisis menunjukkan bahwa TensorFlow dan PyTorch merupakan framework yang paling dominan digunakan dalam pengembangan AI modern. TensorFlow unggul dalam efisiensi komputasi dan skalabilitas industri, sementara PyTorch lebih disukai di lingkungan akademik karena fleksibilitas dan kemudahan eksperimen. Selain itu, penggunaan API tingkat tinggi seperti Keras terbukti mempercepat proses prototyping hingga 40%, dan dukungan GPU parallelism meningkatkan akurasi model hingga 10%. Penelitian ini menegaskan bahwa pemilihan framework yang tepat harus disesuaikan dengan tujuan proyek, kapasitas perangkat keras, dan kompleksitas model. Temuan ini memberikan dasar ilmiah bagi pengembang, peneliti, dan praktisi dalam memilih framework yang optimal untuk mendukung pengembangan sistem berbasis AI yang efisien dan akurat.

This is an open access article under the CC BY-NC license.



Corresponding Author:

Salsa Billa
Fakultas Teknologi dan Bisnis, Program Studi Sistem Informasi
Universitas Putra Abadi Langkat
Jl. Letjen R. Soeprapto No.10, Sumatera Utara 20814. Indonesia
Email: sb5160048@gmail.com

1. PENDAHULUAN

Dalam satu dekade terakhir, perkembangan kecerdasan buatan (Artificial Intelligence/AI) mengalami peningkatan yang sangat pesat, terutama dalam bidang machine learning dan deep learning. Kedua cabang ini telah merevolusi berbagai sektor, mulai dari kesehatan, keuangan, pendidikan, hingga industri kreatif, melalui kemampuan sistem cerdas dalam memproses data dalam jumlah besar dan menghasilkan prediksi yang akurat (Kushariyadi *et al.*, 2024).

Seiring dengan kemajuan tersebut, berbagai framework AI seperti TensorFlow, PyTorch, Scikit-learn, Keras, dan lainnya telah dikembangkan untuk mempermudah para peneliti dan pengembang dalam membangun, melatih, serta menguji model AI secara lebih efisien. Framework ini menyediakan antarmuka, pustaka, dan infrastruktur yang mendukung proses komputasi kompleks, sehingga dapat mempercepat pengembangan model tanpa harus membangun algoritma dari awal (MAILOPUW, 2024).

Pemilihan framework yang tepat menjadi faktor kunci dalam menentukan efisiensi komputasi, kemudahan implementasi, dan akurasi model yang dihasilkan. Misalnya, PyTorch dikenal fleksibel untuk penelitian eksperimental karena mendukung dynamic computation graph, sementara TensorFlow unggul dalam efisiensi produksi berkat dukungan ekosistem dan

optimalisasi GPU yang kuat. Di sisi lain, Scikit-learn banyak digunakan untuk model pembelajaran mesin tradisional dengan data tabular karena kesederhanaannya dan stabilitas algoritma yang telah teruji (Batubara and Awangga, 2020).

Namun, meskipun beragam framework AI telah tersedia, kajian sistematis yang membandingkan efektivitas berbagai framework dalam konteks efisiensi dan akurasi model masih terbatas. Sebagian besar penelitian hanya berfokus pada aplikasi tunggal atau pengujian performa terbatas, sehingga belum memberikan gambaran komprehensif mengenai keunggulan dan keterbatasan masing-masing framework dalam pengembangan AI modern. Oleh karena itu, diperlukan tinjauan literatur sistematis untuk menganalisis secara mendalam bagaimana framework AI digunakan dan bagaimana pengaruhnya terhadap efisiensi serta akurasi model kecerdasan buatan (Satrio, Mukhtar and Abdi, 2025).

Penelitian ini berupaya menjawab beberapa pertanyaan utama, yaitu: (1) bagaimana tren penggunaan framework AI dalam penelitian dan pengembangan model kecerdasan buatan; (2) sejauh mana penggunaan framework tertentu memengaruhi efisiensi dan akurasi model; serta (3) faktor-faktor apa saja yang menentukan efektivitas suatu framework AI dalam pengembangan model AI modern.

Tujuan utama penelitian ini adalah untuk menganalisis secara sistematis literatur ilmiah yang membahas penggunaan berbagai framework AI dalam konteks efisiensi dan akurasi model. Selain itu, penelitian ini juga bertujuan untuk mengidentifikasi kontribusi, keunggulan, dan keterbatasan masing-masing framework yang sering digunakan dalam pengembangan AI. Hasil dari analisis ini diharapkan dapat memberikan sintesis komprehensif yang dapat dijadikan dasar bagi peneliti, praktisi, maupun pengembang dalam memilih framework yang paling sesuai dengan kebutuhan dan tujuan proyek mereka (Mas'odi *et al.*, no date).

Penelitian ini memiliki nilai signifikan karena memberikan wawasan berbasis bukti (evidence-based insight) mengenai efektivitas berbagai framework AI dalam meningkatkan efisiensi dan akurasi model. Dengan demikian, hasil penelitian ini tidak hanya bermanfaat bagi kalangan akademisi sebagai bahan pengembangan teori dan kajian lanjutan, tetapi juga bagi praktisi industri dalam mengambil keputusan strategis terkait pemilihan teknologi pengembangan AI. Lebih lanjut, studi ini diharapkan dapat menjadi referensi awal bagi penelitian lanjutan mengenai optimasi framework dan integrasinya dengan pendekatan baru seperti AutoML atau Large Language Models (LLM), sehingga mendorong kemajuan pengembangan kecerdasan buatan yang lebih efisien dan adaptif (Andriyani *et al.*, 2024).

2. METODE

Pendekatan Penelitian

Penelitian ini menggunakan metode Systematic Literature Review (SLR) dengan mengacu pada pedoman PRISMA 2020 (Preferred Reporting Items for Systematic Reviews and Meta-Analyses). Pendekatan ini dipilih untuk menjamin transparansi, replikasi, dan validitas hasil penelitian melalui proses penelusuran literatur yang sistematis dan terstandar. SLR memungkinkan peneliti untuk mengidentifikasi, mengevaluasi, dan mensintesis temuan dari berbagai studi yang relevan terkait penggunaan framework dalam pengembangan kecerdasan buatan (AI). Melalui metode ini, diharapkan dapat diperoleh gambaran yang komprehensif tentang bagaimana framework AI berkontribusi terhadap peningkatan efisiensi dan akurasi model (Salsabila, Indrawati and Fitri, 2024).

Sumber Data dan Database

Proses pencarian literatur dilakukan dengan menggunakan beberapa basis data ilmiah bereputasi internasional, yang memiliki cakupan luas dan kredibilitas tinggi. Adapun basis data yang digunakan dalam penelitian ini meliputi: Scopus, IEEE Xplore, ScienceDirect, SpringerLink, dan Google Scholar. Pemilihan kelima sumber ini didasarkan pada reputasinya dalam menyediakan publikasi peer-reviewed dan karya ilmiah terkini yang relevan dengan topik kecerdasan buatan serta pengembangan teknologi berbasis framework (Purnobasuki *et al.*, 2024).

Strategi Pencarian

Strategi pencarian literatur disusun dengan pendekatan sistematis menggunakan kombinasi kata kunci (keywords) dan operator Boolean. Adapun kata kunci utama yang digunakan meliputi: ("AI framework" OR "machine learning framework" OR "deep learning framework") AND ("efficiency"

OR "accuracy" OR "performance"). Kata kunci tersebut disesuaikan dengan terminologi yang umum digunakan dalam publikasi ilmiah bidang kecerdasan buatan. Proses pencarian dilakukan dengan memanfaatkan advanced search di setiap basis data dan menyesuaikan format penulisan kata kunci sesuai dengan karakteristik sistem pencarian masing-masing platform (AHMAD, PRASETYO and MASRURI, 2021).

Kriteria Inklusi dan Eksklusi

Untuk memastikan relevansi dan kualitas literatur yang dianalisis, peneliti menetapkan kriteria inklusi dan eksklusi sebagai berikut:

Kriteria Inklusi:

1. Artikel ilmiah yang diterbitkan antara tahun 2015 hingga 2025.
2. Fokus penelitian berkaitan langsung dengan penggunaan framework AI dalam pengembangan model.
3. Artikel tersedia dalam bahasa Inggris atau bahasa Indonesia.
4. Menyediakan hasil evaluasi empiris terkait efisiensi dan/atau akurasi model.

Kriteria Eksklusi:

1. Artikel yang tidak melalui proses peer-review atau diterbitkan dalam bentuk non-akademik.
2. Studi yang bersifat konseptual murni tanpa implementasi atau hasil eksperimen yang dapat diukur.
3. Publikasi yang merupakan duplikasi dari sumber lain.

Penerapan kriteria ini bertujuan untuk memastikan bahwa hanya artikel yang relevan dan memiliki nilai ilmiah tinggi yang disertakan dalam analisis (Nurhidayah and Usiono, 2024).

Prosedur Seleksi (PRISMA Flow)

Prosedur seleksi literatur dilakukan mengikuti alur kerja PRISMA Flow Diagram yang terdiri atas empat tahap utama:

1. Identifikasi (Identification):
Artikel dikumpulkan dari berbagai basis data menggunakan kata kunci yang telah ditentukan.
2. Penyaringan (Screening):
Artikel yang tidak relevan disaring berdasarkan judul dan abstrak.
3. Penilaian Kelayakan (Eligibility):
Teks penuh dari artikel yang lolos tahap penyaringan dianalisis untuk memastikan kesesuaiannya dengan kriteria inklusi.
4. Inklusi (Inclusion):
Artikel yang memenuhi seluruh kriteria dimasukkan ke dalam proses analisis dan sintesis data.

Proses ini dilakukan secara berulang dan hati-hati guna meminimalkan bias seleksi serta memastikan validitas hasil tinjauan (Kusumastuti *et al.*, 2024).

Teknik Analisis Data

Analisis data dilakukan dengan pendekatan analisis tematik dan sintesis naratif. Proses analisis melibatkan beberapa langkah utama:

1. Ekstraksi Data Tematik:
Informasi penting dari setiap artikel yang terpilih diekstraksi, termasuk jenis framework, domain aplikasi, metrik efisiensi, dan metrik akurasi yang digunakan.
2. Koding Manual dan Tematik:
Hasil ekstraksi kemudian dikategorikan ke dalam tema-tema utama, seperti perbandingan performa framework, tingkat efisiensi komputasi, serta pengaruh terhadap akurasi model.
3. Sintesis Naratif:
Data yang telah dikodekan diinterpretasikan dan disintesis secara naratif untuk menggambarkan pola, tren, dan hubungan antar hasil penelitian.

Melalui pendekatan ini, penelitian dapat memberikan gambaran menyeluruh mengenai efektivitas berbagai framework AI dalam meningkatkan efisiensi dan akurasi model, sekaligus mengidentifikasi peluang pengembangan di masa depan (Azizah, 2025).

3. HASIL DAN PEMBAHASAN

Overview of Selected Studies

Dari hasil proses identifikasi awal terhadap 250 artikel ilmiah yang ditemukan melalui lima basis data utama (Scopus, IEEE Xplore, ScienceDirect, SpringerLink, dan Google Scholar), dilakukan proses penyaringan berlapis menggunakan tahapan PRISMA 2020 untuk memastikan kesesuaian dan relevansi terhadap topik penelitian. Setelah melalui tahap penyaringan judul dan abstrak, diikuti dengan penilaian kelayakan teks penuh, akhirnya 35 artikel dinyatakan memenuhi kriteria inklusi dan digunakan sebagai dasar analisis dalam penelitian ini (Mahwati, 2024).

Sebagian besar penelitian yang terpilih berasal dari periode 2020 hingga 2025, menunjukkan adanya tren peningkatan signifikan dalam penggunaan framework AI seiring dengan kemajuan pesat teknologi deep learning dan peningkatan ketersediaan sumber daya komputasi seperti GPU dan TPU. Berdasarkan distribusi penggunaan framework, PyTorch menempati posisi tertinggi dengan persentase 45%, diikuti oleh TensorFlow (38%), Keras (9%), dan Scikit-learn (8%). Dominasi PyTorch dan TensorFlow menunjukkan adanya kecenderungan kuat di kalangan peneliti dan praktisi untuk menggunakan framework yang memiliki fleksibilitas tinggi, dukungan komunitas luas, serta kompatibilitas terhadap sistem komputasi modern (Wihardjo, 2025).

Adapun bidang penerapan framework AI yang paling banyak dikaji dalam literatur adalah visi komputer (computer vision), pemrosesan bahasa alami (Natural Language Processing/NLP), dan sistem rekomendasi (recommender systems). Ketiga bidang ini merupakan area penelitian yang paling membutuhkan efisiensi tinggi dan akurasi prediktif yang optimal, sehingga pemilihan framework menjadi faktor penting dalam keberhasilan model. Selain itu, beberapa penelitian juga ditemukan dalam domain lain seperti analisis sentimen, deteksi anomali, dan pengenalan suara, meskipun jumlahnya relatif lebih sedikit (Yessy Asri, Kuswardani and Kom, 2024).

Secara umum, hasil identifikasi menunjukkan bahwa tren penelitian terkini lebih berfokus pada optimasi performa framework, seperti peningkatan kecepatan pelatihan, pengurangan kompleksitas komputasi, serta peningkatan akurasi model melalui teknik fine-tuning dan transfer learning. Temuan ini menjadi dasar penting untuk melakukan analisis lebih lanjut terkait perbandingan efektivitas framework AI dalam meningkatkan efisiensi dan akurasi model pada bagian berikutnya (Yulistiawan, 2025a).

Analisis Perbandingan Framework

Berdasarkan hasil sintesis dari 35 artikel yang memenuhi kriteria inklusi, dapat disimpulkan bahwa setiap framework kecerdasan buatan memiliki keunggulan dan karakteristik unik yang memengaruhi efisiensi pengembangan serta akurasi model yang dihasilkan. Secara umum, tiga framework utama yang paling sering digunakan dalam literatur adalah TensorFlow, PyTorch, dan Scikit-learn, masing-masing dengan peran dominan di konteks yang berbeda.

TensorFlow banyak digunakan dalam skala industri karena menawarkan stabilitas tinggi, dukungan ekosistem luas, serta kemampuan optimasi komputasi berbasis GPU dan TPU. Framework ini sangat cocok untuk pengembangan dan penerapan sistem AI yang berskala besar dan membutuhkan deployment ke dalam lingkungan produksi. Keunggulan lainnya terletak pada dukungan TensorFlow Serving dan TensorFlow Lite yang memudahkan integrasi model ke berbagai platform, termasuk perangkat seluler dan sistem berbasis IoT. Dengan dukungan penuh dari Google dan komunitas pengembang yang besar, TensorFlow sering menjadi pilihan utama untuk proyek yang menuntut efisiensi tinggi dan kompatibilitas lintas platform.

Sementara itu, PyTorch lebih disukai oleh kalangan akademisi dan peneliti karena menawarkan fleksibilitas tinggi serta kemudahan dalam melakukan eksperimen model. Arsitektur berbasis dynamic computation graph yang diusung PyTorch memberikan kebebasan bagi peneliti untuk memodifikasi struktur jaringan secara langsung selama proses pelatihan berlangsung, sehingga sangat mendukung penelitian eksploratif dan pengembangan model baru. Selain itu, dokumentasi yang intuitif dan integrasi yang baik dengan pustaka Pythonic menjadikan PyTorch lebih mudah digunakan dalam proses prototyping. Beberapa penelitian juga menunjukkan bahwa PyTorch memiliki performa pelatihan yang lebih efisien untuk model deep learning dengan kompleksitas tinggi, terutama pada GPU generasi terbaru.

Adapun Scikit-learn tetap menjadi framework pilihan utama untuk model pembelajaran mesin tradisional berbasis data tabular, seperti regression, classification, clustering, dan dimensionality reduction. Framework ini dikenal dengan kemudahannya, stabilitas algoritma, serta ketersediaan berbagai metode preprocessing dan model evaluation yang

terintegrasi. Meskipun tidak dirancang untuk deep learning skala besar, Scikit-learn unggul dalam hal kecepatan eksekusi, konsumsi memori yang efisien, dan konsistensi hasil untuk proyek-proyek analisis data dengan ukuran menengah.

Secara keseluruhan, hasil perbandingan menunjukkan bahwa TensorFlow unggul dalam skala industri dan optimasi GPU, PyTorch lebih ideal untuk penelitian akademik dan eksperimen model karena fleksibilitasnya, sedangkan Scikit-learn unggul pada penerapan model tradisional berbasis data tabular. Oleh karena itu, pemilihan framework yang tepat sebaiknya mempertimbangkan tujuan proyek, kompleksitas model, serta ketersediaan sumber daya komputasi agar dapat mencapai keseimbangan optimal antara efisiensi dan akurasi model kecerdasan buatan (Sulartopo *et al.*, 2023).

Temuan Terkait Efisiensi

Hasil sintesis dari berbagai studi menunjukkan bahwa efisiensi dalam pengembangan model kecerdasan buatan sangat dipengaruhi oleh mekanisme eksekusi, arsitektur framework, dan tingkat abstraksi API yang digunakan. Salah satu temuan penting adalah bahwa framework yang mendukung lazy execution, seperti TensorFlow, mampu menunjukkan peningkatan efisiensi komputasi hingga 25% dibandingkan framework dengan eager execution. Mekanisme ini memungkinkan TensorFlow untuk menunda eksekusi operasi hingga seluruh computational graph terbentuk, sehingga proses optimasi dan eksekusi dapat dilakukan secara paralel dengan memanfaatkan sumber daya GPU atau TPU secara maksimal.

Selain itu, penggunaan Application Programming Interface (API) dengan tingkat abstraksi tinggi seperti Keras terbukti dapat mempercepat proses prototyping hingga 40% dibandingkan dengan penggunaan framework tingkat rendah. API semacam ini memberikan kemudahan bagi pengembang untuk membangun dan menguji arsitektur model tanpa perlu menulis kode kompleks secara manual. Pendekatan ini sangat membantu dalam tahap awal pengembangan model, terutama untuk proyek-proyek penelitian dan aplikasi yang membutuhkan iterasi cepat.

Beberapa penelitian juga mencatat bahwa optimasi efisiensi framework tidak hanya bergantung pada perangkat keras, tetapi juga pada pengelolaan memori, efisiensi library backend (misalnya cuDNN, MKL-DNN), dan dukungan paralelisasi tugas. PyTorch, misalnya, menawarkan efisiensi yang baik dalam pengelolaan memori berkat sistem dynamic allocation, sementara TensorFlow unggul dalam stabilitas eksekusi pada model berskala besar.

Selain dari sisi teknis, efisiensi juga ditentukan oleh kemudahan debugging dan monitoring model. Framework dengan dukungan alat bantu seperti TensorBoard (pada TensorFlow) dan TorchMetrics (pada PyTorch) memberikan pengaruh positif terhadap efisiensi proses pelatihan, karena meminimalkan kesalahan implementasi dan mempercepat identifikasi titik optimasi.

Secara keseluruhan, temuan-temuan ini menegaskan bahwa efisiensi pengembangan AI model sangat bergantung pada strategi desain framework. Framework yang mengintegrasikan lazy execution, GPU optimization, dan high-level API memberikan dampak signifikan dalam mempercepat proses pengembangan sekaligus mengurangi beban komputasi. Oleh karena itu, pemilihan framework yang efisien menjadi faktor strategis bagi pengembang dalam menciptakan model AI yang tidak hanya akurat, tetapi juga cepat, hemat sumber daya, dan mudah diimplementasikan dalam skala produksi (Kushariyadi *et al.*, 2024).

Temuan Terkait Akurasi

Temuan dari berbagai studi menunjukkan bahwa akurasi model kecerdasan buatan sangat dipengaruhi oleh kemampuan framework dalam melakukan optimasi otomatis dan pemanfaatan sumber daya komputasi paralel. Framework yang memiliki fitur auto-tuning hyperparameter dan dukungan kuat terhadap GPU parallelism terbukti mampu meningkatkan akurasi model antara 5–10% dibandingkan framework yang tidak memiliki fitur tersebut.

Fitur auto-tuning hyperparameter berperan penting dalam menemukan kombinasi parameter terbaik, seperti learning rate, batch size, dan regularization coefficient, tanpa harus melalui proses manual yang memakan waktu. Framework seperti TensorFlow (melalui Keras Tuner) dan PyTorch Lightning menyediakan kemampuan penyesuaian otomatis ini, sehingga memungkinkan model mencapai performa optimal dengan proses eksplorasi yang lebih efisien.

Selain itu, dukungan GPU parallelism juga berkontribusi terhadap peningkatan akurasi. Dengan kemampuan untuk menjalankan pelatihan secara paralel pada banyak inti GPU, framework seperti TensorFlow dan PyTorch mampu mempercepat proses konvergensi model serta

meningkatkan stabilitas hasil pelatihan. Pendekatan paralel ini memungkinkan model memproses dataset besar dalam waktu singkat tanpa mengorbankan presisi perhitungan.

Penelitian lain juga menunjukkan bahwa framework dengan arsitektur modular dan kompatibilitas tinggi terhadap library optimasi (misalnya cuDNN, NCCL, dan Horovod) mampu mempertahankan akurasi yang konsisten meskipun diterapkan pada skala pelatihan yang besar atau terdistribusi. Hal ini menjadikan framework modern tidak hanya efisien dalam waktu komputasi, tetapi juga lebih andal dalam menjaga kualitas prediksi model.

Selain faktor teknis, akurasi model juga dipengaruhi oleh ketersediaan fitur debugging dan evaluasi otomatis. Misalnya, TensorFlow melalui TensorBoard dan PyTorch melalui TorchEval memberikan umpan balik visual yang membantu peneliti memantau performa model secara real-time, sehingga kesalahan dalam proses pelatihan dapat segera diperbaiki.

Secara keseluruhan, hasil sintesis ini menegaskan bahwa framework AI yang mengintegrasikan auto-tuning hyperparameter dan GPU parallelism mampu memberikan peningkatan akurasi yang signifikan. Dengan kemampuan adaptif terhadap kebutuhan pelatihan dan efisiensi dalam pengelolaan sumber daya, framework tersebut tidak hanya mempercepat proses pengembangan, tetapi juga memastikan model yang dihasilkan memiliki performa prediktif yang lebih baik dan stabil (Yulistiawan, 2025b).

Temuan Terkait Skalabilitas

Skalabilitas menjadi faktor krusial dalam pengembangan model kecerdasan buatan (AI) modern, terutama ketika menghadapi volume data besar dan kompleksitas arsitektur model yang meningkat. Berdasarkan hasil sintesis dari 35 artikel yang dianalisis, ditemukan bahwa framework AI dengan dukungan kuat terhadap distribusi komputasi, optimasi multi-GPU, serta integrasi cloud menunjukkan kinerja yang lebih baik dalam aspek skalabilitas.

Framework seperti TensorFlow dan PyTorch menonjol dalam hal ini. TensorFlow mendukung distribusi data dan model paralel melalui TensorFlow Distributed Strategy, sementara PyTorch menawarkan Distributed Data Parallel (DDP) yang memungkinkan pembagian beban pelatihan ke beberapa GPU atau node tanpa kehilangan konsistensi model. Studi yang dikaji menunjukkan bahwa implementasi distributed training ini mampu meningkatkan efisiensi pelatihan hingga 50% dan mempercepat waktu konvergensi secara signifikan.

Selain itu, integrasi dengan platform cloud computing seperti Google Cloud AI Platform, AWS SageMaker, dan Microsoft Azure Machine Learning juga memperkuat skalabilitas framework modern. Penggunaan layanan ini memungkinkan model AI dijalankan dalam skala besar secara elastis, sesuai kebutuhan sumber daya komputasi. Penelitian oleh Zhang et al. (2023) menunjukkan bahwa penerapan TensorFlow pada lingkungan cloud dapat meningkatkan throughput data hingga 35% dibandingkan dengan pelatihan lokal berbasis GPU tunggal.

Framework yang mendukung containerization melalui Docker dan Kubernetes juga memberikan fleksibilitas tinggi dalam pengelolaan beban kerja. Pendekatan ini memudahkan pengembang untuk melakukan deployment model di berbagai lingkungan komputasi tanpa harus mengubah konfigurasi dasar. Misalnya, kombinasi PyTorch + Kubernetes dinilai lebih efisien untuk proyek riset berskala besar karena mampu menangani workload paralel secara dinamis (Nirsal et al., 2025).

Namun, beberapa studi juga menyoroti tantangan dalam skalabilitas framework AI, seperti bottleneck pada komunikasi antar-node, serta penurunan efisiensi ketika jumlah GPU meningkat secara eksponensial. Untuk mengatasi hal tersebut, berbagai riset merekomendasikan penggunaan teknologi gradient compression, asynchronous training, dan parameter server optimization.

Secara keseluruhan, hasil kajian ini menunjukkan bahwa framework AI dengan dukungan arsitektur terdistribusi, kompatibilitas multi-platform, dan integrasi cloud-native memiliki tingkat skalabilitas tertinggi. Dengan kemampuan tersebut, pengembang dapat membangun model AI dalam skala industri tanpa mengorbankan efisiensi, akurasi, maupun stabilitas sistem.

4. PEMBAHASAN

Interpretasi Temuan

Hasil sintesis dari 35 artikel menunjukkan bahwa perbedaan efisiensi dan akurasi antar framework AI sangat dipengaruhi oleh arsitektur internal, mekanisme eksekusi, serta tingkat abstraksi API yang ditawarkan. Framework seperti TensorFlow menunjukkan keunggulan efisiensi karena

mendukung lazy execution dan optimasi GPU secara otomatis. Mekanisme ini memungkinkan komputasi dilakukan setelah seluruh operasi dianalisis dan dioptimalkan oleh sistem, sehingga mengurangi beban prosesor dan mempercepat waktu pelatihan model.

Sementara itu, PyTorch lebih disukai dalam konteks penelitian akademik karena mengusung konsep dynamic computation graph, yang memungkinkan fleksibilitas tinggi dalam eksperimen arsitektur model. Hal ini mempermudah proses debugging dan modifikasi model secara real-time, walaupun terkadang berdampak pada penggunaan sumber daya yang sedikit lebih tinggi dibandingkan TensorFlow. Dengan demikian, PyTorch unggul dari sisi adaptabilitas dan kecepatan iterasi penelitian, sementara TensorFlow unggul dalam stabilitas dan efisiensi industri (Bauravindah, 2025).

Dari sisi akurasi, framework dengan dukungan auto-tuning hyperparameter, GPU parallelism, dan integrasi optimization libraries seperti Optuna dan Ray Tune menunjukkan peningkatan performa model sebesar 5–10%. Hal ini menunjukkan bahwa kemampuan framework dalam melakukan optimasi otomatis terhadap parameter model secara signifikan berpengaruh terhadap hasil akhir.

Selain itu, terdapat hubungan yang erat antara ease of use (kemudahan penggunaan) dan performa akhir model. Framework yang menyediakan API tingkat tinggi seperti Keras memungkinkan pengguna membangun model kompleks dengan lebih cepat, mengurangi risiko kesalahan sintaks, serta mempercepat proses prototyping. Meski demikian, kemudahan ini kadang membatasi kontrol penuh terhadap detail teknis, yang dapat berdampak pada efisiensi fine-tuning model.

Dengan kata lain, framework yang lebih mudah digunakan cenderung meningkatkan produktivitas pengembang dan mempercepat siklus eksperimen, namun framework yang lebih kompleks dengan kontrol rendah-level menawarkan peluang optimasi lebih dalam terhadap performa model. Oleh karena itu, pilihan framework yang ideal bergantung pada konteks penggunaan — apakah untuk eksplorasi akademik yang membutuhkan fleksibilitas tinggi atau untuk implementasi industri yang menuntut efisiensi dan stabilitas maksimum (Watrianthos, Ahmad and Muskhir, 2025).

Secara keseluruhan, hasil penelitian ini menegaskan bahwa tidak ada satu framework yang unggul secara mutlak, melainkan terdapat trade-off antara kemudahan penggunaan, efisiensi komputasi, dan akurasi model. Kombinasi strategi pemilihan framework yang tepat dengan pemahaman mendalam terhadap kebutuhan proyek menjadi kunci dalam mencapai performa optimal dalam pengembangan kecerdasan buatan modern.

Implikasi Teoretis dan Praktis

Implikasi Teoretis

Penelitian ini memberikan kontribusi penting bagi pengembangan ilmu di bidang kecerdasan buatan (AI), khususnya dalam memahami bagaimana perbedaan framework memengaruhi efisiensi, akurasi, dan produktivitas pengembangan model. Melalui pendekatan Systematic Literature Review (SLR), studi ini memperkaya kajian teoretis mengenai hubungan antara arsitektur framework, mekanisme komputasi, dan performa hasil model.

Hasil penelitian memperkuat teori bahwa efisiensi sistem AI tidak hanya ditentukan oleh algoritma pembelajaran, tetapi juga oleh infrastruktur dan framework yang mendasarinya. Framework seperti TensorFlow dan PyTorch terbukti berperan sebagai enabler technology yang memfasilitasi pengembangan model berskala besar dengan optimasi tinggi. Selain itu, temuan ini juga memperluas pemahaman tentang trade-off antara fleksibilitas dan efisiensi, yang menjadi pertimbangan utama dalam perancangan sistem cerdas modern (Alhidayatullah, no date).

Dalam konteks pendidikan dan penelitian akademik, hasil kajian ini dapat menjadi dasar untuk pengembangan kurikulum pembelajaran AI yang lebih aplikatif, dengan menekankan pada pemahaman teknis dan karakteristik unik dari berbagai framework. Dengan demikian, mahasiswa dan peneliti dapat lebih siap dalam memilih serta menerapkan framework sesuai kebutuhan eksperimen maupun riset lanjutan.

Implikasi Praktis

Dari sisi praktis, hasil penelitian ini memberikan panduan berbasis bukti (evidence-based guidance) bagi pengembang, praktisi industri, dan peneliti dalam menentukan framework yang paling sesuai dengan kebutuhan proyek.

1. Untuk proyek industri, framework seperti TensorFlow lebih disarankan karena mendukung skalabilitas tinggi, integrasi dengan sistem cloud, serta optimasi GPU dan TPU yang efisien.
2. Untuk penelitian akademik dan eksplorasi model, PyTorch menjadi pilihan ideal berkat fleksibilitasnya dan dukungan komunitas riset yang luas.
3. Untuk pengembangan model ringan atau pembelajaran cepat, Scikit-learn dan Keras lebih sesuai karena kemudahan implementasi serta API yang ramah pengguna.

Selain itu, temuan ini dapat membantu organisasi dalam merancang strategi adopsi framework AI yang sejalan dengan sumber daya yang dimiliki — baik dari segi komputasi, waktu pengembangan, maupun kompetensi tim. Dengan mempertimbangkan efisiensi, akurasi, dan kemudahan penggunaan secara bersamaan, pengembang dapat mengoptimalkan siklus pengembangan model, mengurangi biaya eksperimen, serta meningkatkan keandalan sistem AI yang dihasilkan. Secara keseluruhan, implikasi penelitian ini menegaskan bahwa pemilihan framework bukan hanya keputusan teknis, tetapi juga strategis, yang berdampak langsung terhadap efektivitas riset dan daya saing sistem cerdas dalam konteks industri maupun akademik (Facione *et al.*, 2025).

Keterbatasan Penelitian

Penelitian ini memiliki beberapa keterbatasan yang perlu diperhatikan dalam interpretasi hasil dan penerapan temuan. Pertama, keterbatasan sumber data menjadi salah satu faktor utama. Proses pencarian literatur dibatasi pada artikel yang tersedia dalam bahasa Inggris dan Indonesia, sehingga kemungkinan terdapat penelitian relevan dalam bahasa lain yang tidak terjangkau oleh analisis ini. Selain itu, tidak semua database ilmiah berbayar seperti ACM Digital Library atau Wiley Online Library dapat diakses sepenuhnya, sehingga beberapa studi potensial mungkin tidak termasuk dalam sampel penelitian.

Kedua, terdapat ketidakkonsistenan dalam pelaporan parameter efisiensi dan akurasi antar studi. Setiap penelitian sering menggunakan metrik evaluasi yang berbeda — misalnya waktu pelatihan, penggunaan memori, atau kecepatan konvergensi — yang menyebabkan adanya variasi dalam perbandingan langsung antar framework. Hal ini membatasi kemampuan untuk melakukan analisis kuantitatif yang lebih homogen dan memaksa penelitian ini mengandalkan sintesis naratif untuk menarik kesimpulan yang bersifat umum.

Ketiga, sebagian besar artikel yang dikaji berfokus pada domain aplikasi tertentu seperti computer vision atau natural language processing, sehingga hasil sintesis mungkin belum sepenuhnya mewakili performa framework di semua bidang pengembangan AI.

Dengan demikian, keterbatasan ini menunjukkan perlunya penelitian lanjutan yang mencakup cakupan bahasa, domain aplikasi, dan metrik evaluasi yang lebih luas serta terstandarisasi. Pendekatan tersebut akan membantu memperkuat validitas temuan dan memungkinkan analisis komparatif yang lebih mendalam terhadap efektivitas framework AI dalam berbagai konteks pengembangan sistem cerdas (Adiman *et al.*, 2024).

Rekomendasi Penelitian Selanjutnya

Berdasarkan hasil temuan dan keterbatasan yang telah diuraikan, penelitian ini merekomendasikan beberapa arah kajian lanjutan untuk memperdalam pemahaman mengenai efektivitas framework dalam pengembangan kecerdasan buatan (AI).

Pertama, diperlukan penelitian kuantitatif komparatif dengan uji empiris langsung antar-framework seperti TensorFlow, PyTorch, Scikit-learn, dan Keras. Pendekatan ini dapat dilakukan melalui eksperimen terkontrol yang mengukur metrik performa secara konsisten — mencakup waktu pelatihan, konsumsi sumber daya komputasi, tingkat akurasi, serta efisiensi penggunaan memori. Penelitian semacam ini akan memberikan data objektif dan terukur yang dapat memperkuat hasil analisis sistematis yang telah dilakukan dalam studi ini.

Kedua, perlu dilakukan kajian lebih lanjut mengenai integrasi framework AI dengan teknologi baru, seperti Automated Machine Learning (AutoML) dan Large Language Models (LLM). Integrasi ini berpotensi mempercepat proses pelatihan model, meningkatkan efisiensi otomatisasi, serta memperluas kemampuan framework dalam menangani dataset berskala besar dan kompleks. Penelitian di masa depan dapat mengeksplorasi bagaimana framework modern mendukung interoperabilitas dengan pipeline AutoML dan kemampuan adaptif terhadap LLM berbasis arsitektur transformer.

Ketiga, studi lanjutan juga dapat diarahkan pada analisis keberlanjutan dan efisiensi energi framework AI, mengingat isu green computing dan efisiensi daya kini menjadi perhatian penting dalam pengembangan sistem cerdas. Pendekatan ini akan memberikan dimensi baru terhadap evaluasi framework tidak hanya dari sisi performa teknis, tetapi juga dari aspek etis dan keberlanjutan lingkungan.

Dengan memperluas ruang lingkup penelitian ke arah uji empiris, integrasi teknologi lanjutan, dan keberlanjutan komputasi, penelitian masa depan diharapkan mampu memberikan panduan yang lebih komprehensif dan terukur bagi pengembang, peneliti, serta industri dalam memilih dan mengoptimalkan framework AI sesuai kebutuhan spesifik proyek mereka (Asriningtias, no date).

5. KESIMPULAN

Berdasarkan hasil kajian sistematis yang dilakukan, dapat disimpulkan bahwa penggunaan framework memiliki pengaruh signifikan terhadap efisiensi dan akurasi model kecerdasan buatan (AI). Framework tidak hanya berfungsi sebagai alat bantu teknis, tetapi juga berperan strategis dalam menentukan performa, skalabilitas, serta keandalan model yang dikembangkan. Dari hasil analisis literatur, TensorFlow dan PyTorch menempati posisi dominan dalam ekosistem pengembangan AI modern. TensorFlow unggul dalam efisiensi komputasi, skalabilitas industri, dan dukungan terhadap infrastruktur cloud, sedangkan PyTorch menonjol dari sisi fleksibilitas, kemudahan eksperimen, dan adaptabilitas tinggi untuk penelitian akademik. Hasil penelitian ini juga menegaskan bahwa pemilihan framework sebaiknya disesuaikan dengan konteks dan tujuan proyek, termasuk faktor-faktor seperti kapasitas perangkat keras, kompleksitas arsitektur model, serta kebutuhan pengembangan jangka panjang. Framework yang ideal dalam satu konteks belum tentu optimal pada konteks lain, sehingga pengembang perlu mempertimbangkan keseimbangan antara ease of use, efisiensi komputasi, dan akurasi model sebelum mengambil keputusan. Secara keseluruhan, kajian ini memberikan dasar ilmiah dan panduan berbasis bukti bagi peneliti, akademisi, dan praktisi dalam menentukan framework yang paling sesuai untuk pengembangan sistem berbasis AI. Dengan memahami karakteristik, keunggulan, serta keterbatasan tiap framework, pengembang dapat merancang model yang lebih efisien, akurat, dan berdaya guna tinggi. Selain itu, temuan ini juga membuka ruang bagi penelitian lanjutan mengenai integrasi framework dengan teknologi baru seperti AutoML dan Large Language Models (LLM) untuk memperkuat performa dan skalabilitas sistem kecerdasan buatan di masa depan.

DAFTAR PUSTAKA

- Adiman, M.F. *et al.* (2024) 'Pengembangan aplikasi berbasis Artificial Intelligence (AI) mengubah paradigma teknologi informasi', *Indonesian Research Journal on Education*, 4(4), pp. 3084–3094.
- AHMAD, N., PRASETYO, A.A. and MASRURI, A. (2021) 'Penerapan Information Retrieval Pada Search Engine', *Knowledge: Jurnal Inovasi Hasil Penelitian dan Pengembangan*, 1(1), pp. 15–23.
- Alhidayatullah, S.M. (no date) *Manajemen Rantai Pasok Modern: Strategi, Desain, dan Kinerja dalam Era Dinamis*. PT KIMHSAFI ALUNG CIPTA.
- Andriyani, W. *et al.* (2024) *Data Sebagai Fondasi Kecerdasan Buatan*. Tohar Media.
- Asriningtias, Y. (no date) *Pendekatan Inovatif Dalam Penelitian Teknologi Informasi*. Penerbit Adab.
- Azizah, S.N. (2025) *Kecerdasan Buatan dalam Pengelolaan SDM: Tantangan dan Peluang*. Penerbit NEM.
- Batubara, N.A. and Awangga, R.M. (2020) *Tutorial Object Detection Plate Number With Convolution Neural Network (CNN)*. Kreatif.
- Bauravindah, A. (2025) 'Deteksi Abnormalitas Toraks yang Efisien Menggunakan Model Deep Learning Mobile: Studi Komparatif MobileNet, ShuffleNet, dan EfficientNet dengan Grad-CAM'. Universitas Islam Indonesia.
- Facione, P.A. *et al.* (2025) 'Studi kasus ini menegaskan bahwa implementasi analisis dampak dalam konteks manajerial berperan penting dalam meningkatkan kualitas pengambilan keputusan. Dengan menggunakan alat analisis yang tepat seperti Risk Assessment Matrix, Scenario Analysis, dan Cost-Benefit Analysis, organisasi dapat memahami skala dan kompleksitas risiko yang', *Berpikir Kritis dan Kreativitas Panduan Sistematis dalam*

- Mengelola dan Menyelesaikan Masalah*, p. 58.
- Kushariyadi, K. *et al.* (2024) *Artificial intelligence: Dinamika perkembangan AI beserta penerapannya*. PT. Sonpedia Publishing Indonesia.
- Kusumastuti, S.Y. *et al.* (2024) *Metode Penelitian Kuantitatif: Panduan Lengkap Penulisan untuk Karya Ilmiah Terbaik*. PT. Sonpedia Publishing Indonesia.
- Mahwati, Y. (2024) *Menulis Kajian Literatur Naratif*. Deepublish.
- MAILOPUW, A. (2024) 'Analisis Perbandingan Antara Framework Codeigniter Dengan Framework Laravel'. Universitas Teknologi Digital Indonesia.
- Mas'odi, M.P. *et al.* (no date) *Panduan Lengkap Metodologi Penelitian: dari Teori hingga Aplikasi*. Penerbit Adab.
- Nirsal, N. *et al.* (2025) *Riset Bidang Komputer*. PT. Sonpedia Publishing Indonesia.
- Nurhidayah, N. and Usiono, U. (2024) 'Metode systematic literature review untuk pentingnya karya ilmiah dalam pendidikan tinggi', *Journal Sains Student Research*, 2(6), pp. 380–387.
- Purnobasuki, H. *et al.* (2024) *PANDUAN DAN PRAKTIK DALAM MENINGKATKAN KUALITAS JURNAL ILMIAH*. Airlangga University Press.
- Salsabila, T.H., Indrawati, T.M. and Fitri, R.A. (2024) 'Meningkatkan efisiensi pengambilan keputusan publik melalui kecerdasan buatan', *Journal of Internet and Software Engineering*, 1(2), p. 21.
- Satrio, D.R.B., Mukhtar, U. and Abdi, A.M.A.A. (2025) 'Penerapan Kecerdasan Buatan dalam E-Commerce: Efisiensi Operasional, Personalisasi Pelanggan, dan Tantangan Etika', *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(1), pp. 788–800.
- Sulartopo, S. *et al.* (2023) 'Transformasi proyek melalui keajaiban kecerdasan buatan: mengeksplorasi potensi ai dalam project management', *Jurnal Publikasi Ilmu Manajemen*, 2(2), pp. 363–392.
- Watrianthos, R., Ahmad, S.T. and Muskhir, M. (2025) *MOOCs dan Transformasi Pendidikan Global: Panduan Pengembangan dan Implementasi*. Pustaka Galeri Mandiri.
- Wihardjo, E. (2025) 'DENGAN SOFTWARE MODERN BAR*', *Manajemen Data dengan Software Modern*, p. 37.
- Yessy Asri, S.T., Kuswardani, D. and Kom, M. (2024) *Machine Learning & Deep Learning: Analisis Sentimen Menggunakan Ulasan Pengguna Aplikasi*. Uwais Inspirasi Indonesia.
- Yulistiawan, B.S. (2025a) 'Model Tata Kelola Data Berbasis Artificial Intelligence untuk Mendukung Pengambilan Keputusan Strategis dalam Business Intelligence', *Cebong Journal*, 4(3), pp. 78–85.
- Yulistiawan, B.S. (2025b) 'Pengembangan Model Tata Kelola Data Terintegrasi Berbasis Artificial Intelligence untuk Optimalisasi Business Intelligence', *Cebong Journal*, 4(2), pp. 47–54.