

Tinjauan Literatur Sistematis (2019–2025) Kinerja Decision Tree dan Neural Network (Deep Learning) serta Perbandingannya dengan Naive Bayes dan SVM

Fahmy Syahputra

Universitas Negeri Medan, Indonesia
famybd@unimed.ac.id

Elsa Sabrina

Universitas Negeri Medan, Indonesia
elsasabrina@unimed.ac.id

Febrinata Silvianna Br Tarigan

Universitas Negeri Medan, Indonesia
febrinata.5231151017@mhs.unimed.ac.id

Matius Irvan Sarumaha

Universitas Negeri Medan, Indonesia
Irvan.5231151011@mhs.unimed.ac.id

Alfi Rahmadhani

Universitas Negeri Medan, Indonesia
alfirahma.5231151021@mhs.unimed.ac.id

Sandha Calista Simanjorang

Universitas Negeri Medan, Indonesia
sandhajorang.5233351009@mhs.unimed.ac.id

Loveyanni Marito Benedikta Gorat

Universitas Negeri Medan, Indonesia
loveyanni.5231151019@mhs.unimed.ac.id

Abstract

This study presents a Systematic Literature Review (2019–2025) comparing the performance of Decision Tree and Neural Network (Deep Learning) models, alongside their relative performance against Naive Bayes and Support Vector Machine (SVM). The review synthesizes empirical findings across multiple application domains—including healthcare, education, industry, and finance—focusing on commonly reported classification metrics such as accuracy, precision, recall, and F1-score. The synthesis indicates that Decision Trees are frequently preferred for structured/tabular data due to their high interpretability and transparent decision rules, which are valuable for accountable decision-making. In contrast, Neural Networks/Deep Learning tend to outperform on unstructured data (e.g., medical images and text) and complex non-linear patterns, albeit often with reduced explainability. In several studies, Naive Bayes remains competitive as a lightweight baseline, while SVM continues to be effective for high-dimensional feature spaces and specific classification settings. Overall, the review highlights that algorithm selection should be driven by data characteristics, problem complexity, interpretability requirements, and computational constraints, since no single algorithm consistently dominates across all scenarios.

Keywords: Classification; Decision Tree; Deep Learning; Naive Bayes; Neural Network; Support Vector Machine (SVM); Systematic Literature Review.

Abstrak

Penelitian ini menyajikan Tinjauan Literatur Sistematis (2019–2025) untuk membandingkan kinerja Decision Tree dan Neural Network (Deep Learning) serta menempatkannya dalam

konteks perbandingan dengan Naive Bayes dan Support Vector Machine (SVM). Studi ini menghimpun dan mensintesis temuan-temuan empiris dari berbagai domain aplikasi—seperti kesehatan, pendidikan, industri, dan keuangan—dengan menitikberatkan pada ukuran kinerja yang umum digunakan pada tugas klasifikasi, termasuk akurasi, presisi, recall, dan F1-score. Hasil sintesis menunjukkan bahwa Decision Tree cenderung unggul pada data terstruktur karena interpretabilitasnya tinggi dan aturan keputusan dapat dijelaskan dengan jelas, sehingga relevan untuk kebutuhan audit dan pengambilan keputusan yang transparan. Sebaliknya, Neural Network/Deep Learning lebih dominan pada data tidak terstruktur (misalnya citra dan teks) serta permasalahan berpola kompleks non-linear, walaupun sering kali memiliki keterbatasan dalam aspek keterjelasan model. Dalam beberapa kasus, Naive Bayes memberikan performa yang kompetitif sebagai baseline yang ringan, sementara SVM tetap kuat pada data berdimensi tinggi dan pola klasifikasi tertentu. Secara keseluruhan, temuan menegaskan bahwa pemilihan algoritma harus mempertimbangkan jenis data, kompleksitas masalah, kebutuhan interpretabilitas, dan sumber daya komputasi, karena tidak ada satu algoritma yang unggul pada seluruh skenario.

KataKunci: Decision Tree; Deep Learning; Klasifikasi; Naive Bayes; Neural Network; Support Vector Machine (SVM); Tinjauan Literatur Sistematis.

1 Pendahuluan

Pada era **transformasi digital** saat ini, pertumbuhan volume data berlangsung sangat cepat dan cenderung meningkat secara eksponensial. Data dihasilkan dari berbagai sumber—mulai dari perangkat bergerak, platform e-commerce, sistem pembelajaran daring, sensor industri, hingga sistem informasi kesehatan—yang pada akhirnya membentuk kumpulan data berskala besar dengan keragaman format dan kualitas. Kondisi ini mendorong perlunya teknik analisis data yang efektif untuk mengekstrak informasi berharga dan menghasilkan pengetahuan yang dapat digunakan dalam pengambilan keputusan. Di tengah kebutuhan tersebut, **pembelajaran mesin (machine learning)** berkembang sebagai solusi yang mampu meningkatkan akurasi, konsistensi, dan efisiensi proses analitik pada berbagai bidang, termasuk kesehatan, pendidikan, serta industri manufaktur (Putra et al., 2024; Rizky & Pratama, 2024). Dengan kemampuan mempelajari pola dari data historis, machine learning dapat membantu organisasi melakukan prediksi, deteksi anomali, klasifikasi, dan otomasi keputusan secara lebih sistematis dibandingkan pendekatan manual atau berbasis aturan statis.

Penerapan machine learning saat ini tidak lagi terbatas pada eksperimen akademik, melainkan telah menjadi bagian penting dari berbagai sistem cerdas. Dalam sektor pendidikan, pembelajaran mesin dapat digunakan untuk memprediksi prestasi belajar peserta didik maupun mengidentifikasi risiko keterlambatan pencapaian kompetensi, sehingga intervensi yang tepat dapat dilakukan lebih dini. Pada ranah ekonomi digital,

model deteksi penipuan dimanfaatkan untuk mengurangi risiko transaksi yang merugikan, terutama pada skema penipuan yang dinamis dan terus berevolusi. Di bidang kesehatan, model klasifikasi dan prediksi menjadi relevan untuk membantu proses penapisan (screening) serta mendukung analisis citra medis, misalnya pada pengenalan pola yang berkaitan dengan tumor otak atau stroke. Ragam contoh tersebut memperlihatkan bahwa machine learning bersifat lintas domain dan adaptif, serta memiliki potensi signifikan dalam meningkatkan kualitas layanan dan efektivitas operasional (Putra et al., 2024; Rizky & Pratama, 2024).

Seiring kemajuan teknologi komputasi dan meningkatnya ketersediaan data, berkembang pula beragam algoritma dan arsitektur pembelajaran mesin. Konsekuensinya, **pemilihan algoritma yang tepat** menjadi isu yang semakin krusial. Pemilihan model yang kurang sesuai dapat menyebabkan performa yang rendah, interpretasi yang menyesatkan, atau bahkan risiko implementasi yang lebih tinggi dalam sistem nyata. Karena itu, pemilihan algoritma tidak dapat bergantung pada tren semata, melainkan perlu mempertimbangkan karakteristik data, tujuan analitik, serta konteks penerapan (Jannah, 2024). Dalam praktiknya, dua masalah sering muncul secara bersamaan: pertama, banyak model yang menunjukkan akurasi tinggi pada kondisi tertentu namun tidak stabil saat data berubah; kedua, ada trade-off yang kuat antara **kinerja prediktif** dan **keterjelasan/interpretabilitas** model. Situasi inilah yang membuat praktisi memerlukan landasan komparatif yang lebih jelas dalam memilih algoritma.

Di antara berbagai algoritma pembelajaran mesin yang populer, **Decision Tree (Pohon Keputusan)** dikenal luas sebagai metode yang efektif untuk **data terstruktur** (tabular) karena menghasilkan aturan keputusan yang mudah dipahami. Struktur pohon memudahkan pengguna menelusuri jalur keputusan dan memahami mengapa suatu prediksi dihasilkan. Karakteristik ini menjadikan Decision Tree relevan untuk konteks yang menuntut transparansi, akuntabilitas, dan penjelasan yang dapat dikomunikasikan ke pemangku kepentingan non-teknis. Selain itu, Decision Tree sering dipandang sebagai model yang relatif mudah diimplementasikan dan menjadi titik awal yang kuat untuk membangun sistem klasifikasi pada beragam kasus. Namun, pada saat yang sama, Decision Tree juga memiliki tantangan seperti potensi overfitting pada data tertentu, sensitivitas terhadap perubahan data, dan keterbatasan dalam menangkap hubungan non-linear yang sangat kompleks jika tidak dipadukan dengan teknik tertentu.

Sebaliknya, **Neural Network (Jaringan Syaraf Tiruan)** dan turunannya, **Deep Learning**, berkembang pesat karena kemampuannya memodelkan hubungan non-linear dan mempelajari representasi fitur secara otomatis. Deep Learning banyak dilaporkan unggul pada **data tidak terstruktur** seperti citra dan teks, yang sering kali sulit diproses oleh model klasik tanpa rekayasa fitur yang intensif. Keunggulan ini terlihat pada berbagai tugas seperti pengenalan pola citra medis, klasifikasi berbasis teks, maupun pemodelan data kompleks lainnya (Sakinah, Badriyah, & Syarif, 2020; Yanuargi et al., 2025). Meskipun demikian, performa tinggi tersebut sering disertai keterbatasan interpretabilitas, kebutuhan data latih yang besar, serta kebutuhan sumber daya komputasi yang lebih tinggi. Karena itulah, keputusan menggunakan Deep Learning perlu mempertimbangkan kesiapan data, tujuan penggunaan, serta kebutuhan penjelasan model dalam implementasi.

Selain Decision Tree dan Neural Network/Deep Learning, algoritma pembanding seperti **Naive Bayes** dan **Support Vector Machine (SVM)** tetap penting dalam kajian komparatif. Naive Bayes sering digunakan sebagai baseline karena sederhana, efisien, dan dapat bekerja cukup baik pada beberapa skenario klasifikasi tertentu, terutama ketika asumsi independensi fitur tidak terlalu melenceng dari kondisi data. Sementara itu, SVM dikenal kuat pada ruang fitur berdimensi

tinggi dan memiliki kemampuan membentuk batas keputusan yang efektif pada kasus tertentu. Dalam praktik riset dan implementasi, Naive Bayes dan SVM kerap dijadikan pembanding untuk menguji apakah peningkatan performa dari model lain memang signifikan dan layak "dibayar" dengan kompleksitas yang lebih tinggi. Dengan demikian, membandingkan Decision Tree dan Neural Network/Deep Learning tanpa menempatkannya terhadap baseline seperti Naive Bayes dan SVM dapat menghasilkan kesimpulan yang kurang utuh.

Tantangan utama bagi praktisi dan peneliti adalah menentukan **kapan** menggunakan model kompleks seperti Deep Learning dan **kapan** model yang lebih sederhana namun transparan seperti Decision Tree atau Naive Bayes justru lebih sesuai. Dalam banyak kasus, kebutuhan sistem tidak hanya menuntut akurasi, tetapi juga menuntut aspek lain seperti keterjelasan penalaran model, stabilitas performa, kemudahan pemeliharaan, serta efisiensi komputasi. Misalnya, pada beberapa konteks organisasi, model yang "cukup akurat" namun mudah dijelaskan dapat lebih bernilai dibandingkan model yang sangat akurat tetapi sulit dipertanggungjawabkan. Dalam konteks lain, terutama pada data tidak terstruktur berskala besar, model kompleks menjadi kebutuhan agar sistem mampu menangkap pola yang tidak dapat dipelajari oleh model sederhana. Oleh sebab itu, pemahaman komparatif yang berbasis bukti menjadi penting untuk membantu pemilihan algoritma yang tepat (Jannah, 2024).

Berdasarkan latar belakang tersebut, penelitian ini disusun dalam bentuk **Tinjauan Literatur Sistematis (2019–2025)** untuk mengidentifikasi, mengkaji, dan membandingkan secara komprehensif implementasi serta kinerja **Decision Tree** dan **Neural Network (Deep Learning)**, sekaligus menempatkannya dalam kerangka perbandingan dengan **Naive Bayes** dan **SVM**. Rentang 2019–2025 dipilih untuk menangkap dinamika perkembangan pendekatan pembelajaran mesin pada periode yang relatif mutakhir, termasuk meluasnya penggunaan Deep Learning pada data tidak terstruktur dan tetap bertahannya model interpretabel pada data terstruktur. Kajian ini berfokus pada hasil-hasil empiris lintas domain (kesehatan, pendidikan, industri, dan keuangan) dengan menyoroti metrik evaluasi yang umum dipakai pada tugas klasifikasi seperti akurasi, presisi, recall, dan F1-score, sebagaimana lazim dilaporkan pada studi implementasi (Putra et al., 2024; Rizky & Pratama, 2024).

Secara konseptual, penelitian ini menekankan bahwa **tidak ada satu algoritma yang selalu unggul pada semua kondisi**. Keunggulan Decision Tree umumnya tampak pada data terstruktur yang menuntut interpretabilitas, sedangkan Neural Network/Deep Learning cenderung dominan pada data tidak terstruktur dan permasalahan kompleks (Sakinah, Badriyah, & Syarif, 2020; Yanuargi et al., 2025). Namun, kesimpulan tersebut perlu dipaparkan secara lebih sistematis dan komparatif melalui sintesis literatur—agar tidak berhenti pada klaim umum, melainkan disajikan sebagai peta kecenderungan berbasis temuan-temuan studi yang relevan. Di sinilah peran SLR menjadi penting: mengorganisasi temuan, menonjolkan pola, dan mengidentifikasi ruang penggunaan paling tepat untuk tiap algoritma, termasuk peran baseline seperti Naive Bayes dan SVM.

Dengan demikian, kontribusi utama penelitian ini adalah menyediakan gambaran terstruktur mengenai kecenderungan performa dan trade-off pemilihan algoritma pada berbagai jenis data dan kebutuhan sistem. Pertama, penelitian ini membantu memetakan kondisi penggunaan model berdasarkan karakteristik data (terstruktur vs tidak terstruktur) serta tingkat kompleksitas masalah. Kedua, penelitian ini menyoroti aspek interpretabilitas sebagai pertimbangan penting dalam implementasi nyata, terutama ketika keputusan model berdampak pada kebijakan atau layanan. Ketiga, melalui perbandingan dengan Naive Bayes dan SVM, penelitian ini memberikan konteks evaluasi yang lebih objektif untuk menilai peningkatan performa yang ditawarkan Decision Tree maupun Neural Network/Deep Learning (Jannah, 2024). Pada akhirnya, hasil kajian ini diharapkan dapat menjadi rujukan bagi praktisi untuk memilih model yang tidak hanya “unggul di atas kertas”, tetapi juga selaras dengan tujuan, batasan, dan kebutuhan implementasi.

2 Metode

Penelitian ini menggunakan pendekatan **Tinjauan Literatur Sistematis (Systematic Literature Review/SLR)** untuk mengidentifikasi, mengevaluasi, dan mensintesis temuan penelitian terkait kinerja algoritma pembelajaran mesin pada berbagai konteks data dan domain aplikasi. SLR dipilih karena mampu memberikan ringkasan bukti yang lebih terstruktur dan komparatif dibandingkan tinjauan naratif, terutama ketika penelitian yang tersedia beragam dari sisi data, metode evaluasi, dan domain penerapan.

1. Sumber Data dan Strategi Pencarian

Prosedur pengumpulan data dilakukan dengan menghimpun artikel dari **jurnal nasional dan internasional** serta **prosiding konferensi** yang diterbitkan pada rentang **2019–2025**. Pencarian difokuskan pada studi yang menerapkan, menguji, atau membandingkan algoritma **Decision Tree** dan **Neural Network (termasuk Deep Learning)** sebagai fokus utama, serta membandingkannya dengan algoritma pembanding **Naive Bayes** dan **Support Vector Machine (SVM)**. Studi yang juga melibatkan **K-Nearest Neighbor (KNN)** tetap dipertimbangkan sebagai pembanding tambahan apabila relevan dan memenuhi kriteria inklusi.

Agar hasil pencarian konsisten dan dapat direplikasi, kata kunci disusun berdasarkan kombinasi tiga komponen utama:

- **Komponen algoritma:** “Decision Tree”, “Neural Network”, “Deep Learning”, “Naive Bayes”, “Support Vector Machine”, “SVM”, “KNN”
- **Komponen tugas:** “classification”, “prediction”, “performance”, “comparative”, “evaluation”
- **Komponen domain (opsional):** “healthcare”, “medical imaging”, “education”, “industry”, “manufacturing”, “fraud detection”

Contoh pola query (ilustratif): (“Decision Tree” OR “Neural Network” OR “Deep Learning”) AND (“Naive Bayes” OR “SVM” OR “Support Vector Machine”) AND (“classification” OR “performance” OR “comparative”)

2. Kriteria Seleksi Artikel

Seleksi artikel dilakukan menggunakan kriteria inklusi agar studi yang diambil benar-benar relevan dan dapat dibandingkan secara komparatif.

Tabel 1. Kriteria inklusi dan eksklusi

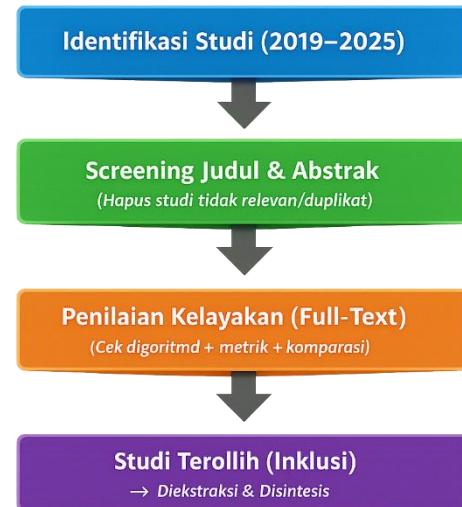
Aspek	Kriteria Inklusi	Kriteria Eksklusi
Topik	Membahas implementasi/eksperimen algoritma ML untuk klasifikasi/prediksi	Tidak membahas implementasi/hasil eksperimen (hanya opini/konseptual)

Algoritma	Memuat Decision Tree dan/atau Neural Network/Deep Learning; serta pembanding Naive Bayes dan/atau SVM (KNN opsional)	Tidak melibatkan algoritma fokus atau tidak relevan dengan komparasi
Evaluasi	Menyajikan metrik evaluasi jelas (mis. Accuracy, Precision, Recall, F1-Score)	Tidak menyajikan metrik kinerja yang dapat diekstraksi
Perbandingan	Ada perbandingan antar algoritma atau optimalisasi yang dilaporkan jelas	Hanya menyebut algoritma tanpa evaluasi komparatif/hasil
Periode	Terbit 2019–2025	Terbit di luar rentang 2019–2025
Domain	Relevan dengan konteks kesehatan, pendidikan, industri, keuangan, atau domain lain yang sepadan	Domain tidak jelas atau data/metode tidak dapat ditelusuri

3. Proses Penyaringan dan Pemilihan Studi

Pemilihan studi dilakukan secara bertahap untuk menjaga konsistensi:

- Identifikasi:** mengumpulkan seluruh artikel yang sesuai kata kunci dan periode publikasi.
- Screening:** menyaring berdasarkan judul dan abstrak untuk menghapus studi yang tidak relevan.
- Kelayakan (eligibility):** membaca teks lengkap untuk memastikan memenuhi semua kriteria inklusi.
- Inklusi akhir:** menetapkan artikel yang digunakan dalam sintesis.



Gambar 1. Alur seleksi studi (bagan SLR)

4. Ekstraksi Data

Dari setiap artikel yang lolos, dilakukan ekstraksi informasi untuk memastikan data antar studi dapat dibandingkan secara konsisten.

Tabel 2. Item ekstraksi data per artikel

Komponen	Isi yang diekstraksi
Identitas studi	Penulis, tahun, jenis publikasi (jurnal/prosiding), domain aplikasi
Karakteristik data	Jenis data (terstruktur/tabular vs tidak terstruktur seperti citra/teks), ukuran data (jika tersedia), jumlah kelas
Algoritma	Model yang digunakan (Decision Tree, NN/DL, Naive Bayes, SVM, KNN), konfigurasi penting (jika dilaporkan)
Pra-pemrosesan	Normalisasi, seleksi fitur, ekstraksi fitur, augmentasi (untuk citra), dsb. (jika dilaporkan)
Evaluasi	Metrik (Accuracy, Precision, Recall, F1-Score), skema validasi (mis. hold-out/k-fold jika dilaporkan)
Hasil utama	Nilai metrik tiap algoritma, algoritma terbaik, dan konteks keunggulannya

5. Analisis dan Sintesis

Analisis dilakukan dengan membandingkan performa algoritma berdasarkan:

- Karakteristik dataset: terstruktur vs tidak terstruktur**
- Kebutuhan interpretabilitas:** transparansi keputusan (lebih condong ke Decision Tree/Naive Bayes) vs performa

- tinggi pada pola kompleks (lebih condong ke NN/DL)
- **Konsistensi metrik:** accuracy, precision, recall, F1-score sebagai pembanding utama

Sintesis hasil disusun secara **komparatif** untuk menarik kesimpulan mengenai:

1. kondisi data dan masalah yang cenderung menguntungkan **Decision Tree**,
2. kondisi yang lebih sesuai untuk **Neural Network/Deep Learning**, dan
3. posisi **Naive Bayes** dan **SVM** sebagai pembanding (serta **KNN** bila relevan) dalam memvalidasi peningkatan kinerja.

Analisis dalam penelitian ini dilakukan dengan **membandingkan performa tiap algoritma** berdasarkan tiga aspek utama, yaitu **karakteristik dataset** (data terstruktur/tabular dibandingkan data tidak terstruktur seperti citra atau teks), **kebutuhan interpretabilitas** (kebutuhan transparansi keputusan yang umumnya lebih sesuai untuk Decision Tree/Naive Bayes dibandingkan kebutuhan performa tinggi pada pola non-linear kompleks yang cenderung lebih sesuai untuk Neural Network/Deep Learning), serta **konsistensi metrik evaluasi** yang digunakan (accuracy, precision, recall, dan F1-score) agar hasil antarstudi dapat disajarkan. Selanjutnya, hasil-hasil yang telah diekstraksi disintesis secara **komparatif** untuk menarik kesimpulan mengenai (1) kondisi data dan jenis permasalahan yang cenderung menguntungkan **Decision Tree**, (2) kondisi yang lebih tepat untuk **Neural Network/Deep Learning**, serta (3) bagaimana **Naive Bayes** dan **SVM** (dan **KNN** bila relevan) berperan sebagai algoritma pembanding untuk memvalidasi apakah peningkatan kinerja yang dilaporkan benar-benar signifikan dan sepadan dengan kompleksitas model yang digunakan.

3 Hasil dan Diskusi

Berdasarkan sintesis berbagai literatur, kinerja algoritma pembelajaran mesin terbukti **sangat bergantung pada konteks domain, karakteristik data, dan tujuan penggunaan** (misalnya kebutuhan transparansi vs kebutuhan akurasi maksimum). Secara umum, **Decision Tree** cenderung unggul pada **data terstruktur (tabular)** ketika interpretabilitas menjadi kebutuhan utama, karena aturan keputusan dapat

dijelaskan secara jelas kepada pemangku kepentingan. Sebaliknya, **Neural Network/Deep Learning** menunjukkan dominasi pada **data tidak terstruktur** (citra/teks) dan pola non-linear yang kompleks, meskipun interpretabilitasnya lebih rendah (Sakinah et al., 2020; Rizky & Pratama, 2024; Yanuargi et al., 2025). Algoritma pembanding seperti **Naive Bayes** tetap kompetitif pada ceruk tertentu (misalnya klasifikasi biner/baseline ringan), sedangkan **SVM** diposisikan sebagai pembanding yang relevan dalam evaluasi kinerja (sesuai kerangka komparatif studi), dan **KNN** muncul sebagai pembanding tambahan pada beberapa penelitian, walaupada dataset besar sering berada di bawah Decision Tree (Harriz & Setiyowati, 2023; Nazifah & Prianto, 2023; Jannah, 2024).

Ringkasan temuan studi yang disintesis

Berikut ringkasan studi kunci yang menjadi dasar pembahasan (angka metrik mengikuti pelaporan pada masing-masing literatur):

Tabel 3. Sintesis Komparatif Kinerja Algoritma pada Berbagai Domain dan Jenis Data (2019–2025)

Studi	Domain	Jenis Data	Algoritma Unggul	Hasil Utama (ringkas)
Jamaluddin & Yonhendri (2025)	Pendidikan (adopsi RDM)	Terstruktur	Decision Tree	Akurasi 89,52% > Naive Bayes 63,81%
Harri z & Setiyowati (2023)	Klasifikasi wilayah	Terstruktur	Decision Tree	Akurasi 85,78%; komputasi 51,66 detik (lebih cepat dari KNN)
Karim & Fahmi (2025)	Deteksi penipuan e-commerce	Terstruktur	Decision Tree	Sensitivitas 0,9992; akurasi 0,9547 (kompetitif)
Sakinah et al. (2020)	Stroke (CT Scan)	Tidak terstruktur (citra)	Deep Learning	Akurasi 96,78% (tertinggi)
Rizky & Prata	Tumor otak (MRI)	Tidak terstruktur (citra)	Neural	Akurasi 0,99

ma (2024)			Netw ork	
Yanu argi et al. (2025)	Analisis sentimen	Tidak terstruktur (teks)	GRU/ LSTM (DL)	Akurasi hingga 98%
Az Zahra et al. (2020)	Personalisasi pembelajaran	Campuran/kontekstual	Deep Learning	Efektif untuk personalisasi; berdampak positif pada numerasi
Aulia et al. (2025)	Preventif kerusakan mesin	Terstruktur	Naive Bayes (biner)	Biner: NB 97,90% > DT 77%; Multikelas: DT lebih unggul
Eryana et al. (2025)	Dataset Iris	Terstruktur	Decision Tree	NB presisi kompetitif; akurasi umumnya di bawah DT
Nazifah & Priantoro (2023)	Dataset besar	Terstruktur	Decision Tree (C4.5)	KNN sering di bawah DT pada dataset besar
Jannah (2024)	Prediksi harga saham	Terstruktur	Decision Tree (C4.5)	Menguatkan temuan KNN < DT pada data besar

1) Kinerja Decision Tree pada data terstruktur: unggul dan interpretabel

Pada data terstruktur, Decision Tree menunjukkan keunggulan yang konsisten, terutama ketika model perlu **mudah dijelaskan**. Pada kasus adopsi teknologi pendidikan, Decision Tree dengan pruning mencapai akurasi **89,52%**, jauh di atas Naive Bayes **63,81%**, sekaligus memudahkan visualisasi faktor determinan seperti kendala teknis dan pelatihan (Jamaluddin & Yonhendri, 2025). Temuan serupa muncul pada klasifikasi wilayah produksi listrik, di mana Decision Tree meraih akurasi **85,78%** dengan waktu komputasi **51,66 detik**, lebih efisien dibanding KNN (Harriz & Setiowati, 2023). Pada deteksi penipuan e-commerce, Decision Tree juga sangat kompetitif dengan sensitivitas **0,9992** dan akurasi **0,9547**, bahkan ketika dibandingkan dengan pendekatan Neural Network (Karim & Fahmi, 2025). Secara diskusi, pola ini

menunjukkan bahwa Decision Tree bukan hanya “cukup akurat”, tetapi juga menawarkan **keunggulan praktis**: transparansi, kemudahan audit, dan kemampuan menjelaskan keputusan—yang penting pada aplikasi operasional.

2) Dominasi Neural Network/Deep Learning pada data tidak terstruktur dan pola kompleks

Berbeda dari data tabular, pada data tidak terstruktur seperti **citra medis** dan **teks**, Neural Network/Deep Learning cenderung unggul karena mampu mempelajari fitur secara otomatis dan menangkap hubungan non-linear yang rumit. Pada klasifikasi stroke berbasis CT Scan, Deep Learning mencapai akurasi **96,78%**, mengungguli metode tradisional (Sakinah et al., 2020). Pada klasifikasi tumor otak berbasis MRI, Neural Network dilaporkan mencapai akurasi **0,99**, menegaskan kekuatan jaringan saraf pada pengenalan pola citra (Rizky & Pratama, 2024). Untuk teks (analisis sentimen), arsitektur GRU dan LSTM mencapai akurasi hingga **98%**, menunjukkan efektivitasnya dalam menangkap konteks kalimat yang tidak mudah ditangani metode konvensional (Yanuargi et al., 2025). Selain itu, Deep Learning juga efektif dalam personalisasi pembelajaran matematika dan berdampak positif pada numerasi siswa (Az Zahra et al., 2020). Diskusinya: dominasi NN/DL terutama muncul ketika **representasi fitur tidak sederhana** dan pola data bersifat kompleks; namun trade-off yang perlu dicatat adalah kebutuhan data/komputasi serta interpretabilitas yang lebih rendah.

3) Posisi Naive Bayes, SVM, dan KNN sebagai pembanding

Algoritma klasik tetap penting sebagai **baseline dan pembanding** untuk memastikan bahwa peningkatan performa dari model tertentu memang signifikan dan bukan sekadar akibat perbedaan data atau skema evaluasi. Naive Bayes, misalnya, menunjukkan anomali menarik: pada klasifikasi biner untuk prediksi preventif kerusakan mesin, Naive Bayes mengungguli Decision Tree (**97,90%** vs **77%**), namun pada klasifikasi multikelas Decision Tree kembali lebih unggul (Aulia et al., 2025). Ini mengindikasikan bahwa Naive Bayes dapat sangat efektif pada skenario tertentu (misalnya biner/fitur tertentu), tetapi performanya dapat menurun ketika struktur kelas dan pola data menjadi lebih kompleks. Pada dataset Iris, Naive Bayes juga memiliki presisi kompetitif meskipun akurasinya umumnya masih di bawah Decision Tree (Eryana et al., 2025).

Untuk KNN, beberapa studi menunjukkan bahwa meskipun metode ini intuitif, performanya sering berada di bawah Decision Tree (C4.5) pada dataset besar (Nazifah & Prianto, 2023; Jannah, 2024). Sementara itu, **SVM** dalam kerangka penelitian ini diposisikan sebagai algoritma pembanding yang relevan (sesuai fokus judul revisi), terutama untuk menguji daya saing model pada kondisi tertentu; namun detail kinerja SVM sangat bergantung pada karakteristik fitur dan konfigurasi yang dilaporkan masing-masing studi (Jannah, 2024). Dengan demikian, Naive Bayes, SVM, dan KNN berperan memperkaya validasi komparatif: membantu menilai kapan model kompleks benar-benar diperlukan dan kapan model lebih sederhana sudah memadai.

Implikasi pemilihan algoritma (selaras dengan revisi)

Secara keseluruhan, sintesis ini menegaskan bahwa pemilihan algoritma sebaiknya mengikuti “aturan konteks”: **Decision Tree** lebih disarankan pada data terstruktur ketika diperlukan transparansi dan interpretabilitas, sedangkan **Neural Network/Deep Learning** lebih tepat pada data tidak terstruktur (citra/teks) dan pola kompleks untuk mengejar performa tinggi (Sakinah et al., 2020; Rizky & Pratama, 2024; Yanuargi et al., 2025). Algoritma pembanding (**Naive Bayes**, **SVM**, serta **KNN** bila relevan) penting untuk memastikan klaim peningkatan kinerja dapat divalidasi dan sepadan dengan kompleksitas implementasi (Aulia et al., 2025; Nazifah & Prianto, 2023; Jannah, 2024).

4 Kesimpulan

Penelitian ini menyimpulkan bahwa **tidak ada satu algoritma yang selalu superior pada semua kondisi**, sehingga pemilihan model harus disesuaikan dengan karakteristik data dan kebutuhan implementasi. **Neural Network/Deep Learning** merupakan pilihan paling tepat untuk **data tidak terstruktur** (seperti citra dan teks) serta permasalahan berpola **kompleks non-linear**, karena secara umum menunjukkan performa sangat tinggi dan konsisten pada berbagai studi, termasuk capaian akurasi yang sering berada pada kisaran **di atas 95%**. Sebaliknya, **Decision Tree** sangat direkomendasikan untuk **data terstruktur (tabular)** terutama ketika sistem membutuhkan **transparansi keputusan (explainability)**, misalnya pada evaluasi kebijakan pendidikan, klasifikasi berbasis indikator, dan konteks manajemen risiko yang menuntut keputusan mudah diaudit. **Naive Bayes** tetap relevan

sebagai baseline yang efisien, khususnya untuk **klasifikasi biner sederhana** dengan kebutuhan komputasi ringan, sementara algoritma pembanding seperti **SVM** (dan **KNN** bila digunakan) membantu memvalidasi peningkatan kinerja secara objektif. Ke depan, penelitian disarankan mengeksplorasi pendekatan **hybrid/ensemble** yang menggabungkan interpretabilitas dan kecepatan model seperti Decision Tree dengan kemampuan representasi fitur dan akurasi tinggi dari Deep Learning agar diperoleh solusi yang lebih seimbang antara performa, transparansi, dan efisiensi.

5 Referensi

- Aulia, I. R., Hermawan, A., & Avianto, D. (2025). Pendekatan hybrid Naïve Bayes dan decision tree untuk prediksi kerusakan mesin pada industri manufaktur PT X. *IJAI (Indonesian Journal of Applied Informatics)*, 9(2), 554-563. <https://doi.org/10.20961/ijai.v9i2.97905>
- Dewi, K. A. K., Fatmawan, A. R., Ilmawan, A. W., & Rusmayani, N. G. A. L. (2025). Analisis penggunaan bahasa Inggris dalam pembelajaran renang: Tinjauan literatur. *Jurnal Pendidikan Olahraga*, 15(3), 127-134. <https://doi.org/10.37630/jpo.v15i3.2609>
- Eryana, D. A., Deivivi, F., Baehaqi, M. I., Wicaksono, A., Puspita, Z. A., & Gultom, H. (2025). Studi komparatif Naive Bayes dan decision tree pada dataset bunga iris: Evaluasi akurasi dan efisiensi. *Jurnal Rekayasa Informasi Swadharma (JRIS)*, 5(2), 192-201. <https://doi.org/10.56486/jris.vol5no2.898>
- Harriz, M. A., & Setiyowati, H. (2023). Komparasi algoritma decision tree dan KNN dalam mengklasifikasi daerah berdasarkan produksi listrik. *JIKO (Jurnal Informatika dan Komputer)*, 7(2), 167-171. <https://doi.org/10.26798/jiko.v7i2.787>
- Irviantina, S. (2025). *Memahami pembelajaran mesin (machine learning): Konsep, algoritma, dan aplikasi*. Padang: Literasi Langsung Terbit.
- Jamaluddin, & Yonhendri. (2025). Prediksi keberhasilan adopsi rapor digital madrasah: Pendekatan terpisah menggunakan algoritma Naive Bayes dan decision tree dengan pruning. *Jatisi (Jurnal Teknik Informatika dan Sistem Informasi)*, 12(2), 442-455.

<https://doi.org/10.35957/jatisi.v12i2.11635>

Jannah, M. (2024). Tinjauan algoritma machine learning untuk prediksi harga saham: Studi literatur. *Jurnal Penelitian Multidisiplin Bangsa*, 1(7), 608-613. <https://doi.org/10.59837/jpnmb.v1i7.121>

Karim, A. A., & Fahmi, F. (2025). Analisis prediktif untuk mendeteksi penipuan e-commerce menggunakan algoritma pembelajaran mesin. *IJCS (The Indonesian Journal of Computer Science)*, 14(2), 3131-3137. <https://doi.org/10.33022/ijcs.v14i2.4202>

Nazifah, N., & Prianto, C. (2023). Analisis perbandingan decision tree algoritma C4.5 dengan algoritma lainnya: Sistematic literature review. *J-ICOM (Jurnal Informatika dan Teknologi Komputer)*, 4(2), 57-64. <https://doi.org/10.55377/jicom.v4i2.7719>

Putra, R. F., Mukhlis, I. R., Datya, A. I., Pipin, S. J., Reba, F., Al-Husaini, M., ... Judijanto, L. (2024). *Algoritma pembelajaran mesin: Dasar, teknik, dan aplikasi*. Jambi: PT. Sonpedia Publishing Indonesia.

Rajagukguk, S. A. (2021). Tinjauan pustaka sistematis: Prediksi prestasi belajar peserta didik dengan algoritma pembelajaran mesin. *Jurnal SNATi*, 1(1), 22-30. <https://doi.org/10.20885/snati.v1i1.4>

Rizky, J. L., & Pratama, Z. P. (2024). Analisis perbandingan algoritma pembelajaran mesin untuk meningkatkan akurasi dan klasifikasi tumor otak. *IJAI (Indonesian Journal of Applied Informatics)*, 9(1), 31-44. <https://doi.org/10.20961/ijai.v9i1.90101>

Sakinah, N., Badriyah, T., & Syarif, I. (2020). Analisis kinerja algoritma mesin pembelajaran untuk klasifikasi penyakit stroke menggunakan citra CT scan. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 7(4), 833-844. <https://doi.org/10.25126/jtiik.202073482>

Sastypratiwi, H., Yulianti, & Muhardi, H. (2022). Uji komparasi algoritma Naïve Bayes dan decision tree classification menggunakan Covid-19 dataset. *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, 8(1), 1-6.

Shafa, B., Handayani, H. H., Lestari, S. A. P., & Cahyana, Y. (2024). Prediksi kanker paru dengan normalisasi menggunakan perbandingan algoritma random forest, decision tree dan Naïve Bayes. *DECODE: Jurnal Pendidikan Teknologi Informasi*, 4(3), 1057-1070.

<https://doi.org/10.51454/decode.v4i3.779>

Tiana, A., & Wahyuni, S. (2025). Analisis strategi pembelajaran abad 21 untuk meningkatkan kreativitas ilmiah siswa SMP: Tinjauan literatur sistematis. *Kalam Cendekia: Jurnal Ilmiah Kependidikan*, 13(2), 1441-1450.

Yanuargi, B., Utami, E., Kusrini, & Parikesit, A. A. (2025). Deep learning neural dalam analisis sentimen: Sebuah studi literatur. *JITSI: Jurnal Ilmiah Teknologi Sistem Informasi*, 6(3), 321-328. <https://doi.org/10.62527/jitsi.6.3.499>

Yusri, A. A., Zainal, M. Z., & Ismail, I. M. (2024). Pembelajaran berdasarkan permainan dalam pengajaran dan pembelajaran bahasa Melayu: Suatu tinjauan literatur. *Jurnal Antarabangsa Alam dan Tamadun Melayu*, 12(1), 15-26. <https://doi.org/10.17576/jatma-2024-1201-02>

Zahra, A. M. A., Shabira, E. N., & Yasin, M. (n.d.). Penerapan algoritma deep learning untuk personalisasi pembelajaran matematika dan dampaknya terhadap kemampuan numerasi. *Program Studi Pendidikan Matematika, Universitas Negeri Malang*.

Andre, R., Wahyu, B., & Purbaningtyas, R. (2021). Klasifikasi tumor otak menggunakan convolutional neural network dengan arsitektur EfficientNet-B3. *Jurnal Sistem Informasi dan Teknologi (JUST IT)*.

Juliastari, J., Artayasa, I. P., & Merta, I. W. (2022). Pengaruh pembelajaran berbasis proyek dengan pendekatan sains teknologi masyarakat terhadap kreativitas ilmiah siswa. *Jurnal Ilmiah Profesi Pendidikan*, 7(2), 337-343. <https://doi.org/10.29303/jipp.v7i2.444>

Laksono, P., & Prabowo, T. (2023). Deteksi tumor otak melalui penerapan GLCM dan Naïve Bayes classification. *Jurnal Ilmiah Intech: Information Technology Journal of UMUS*, 5(1), 41-48. <https://doi.org/10.46772/intech.v5i1.1286>

Wicaksono, I., & Erlina, N. (2024). The effect of virtual science teaching model on scientific creativity and learning outcomes. *Jurnal Pendidikan MIPA*, 25(1), 440-452. <https://doi.org/10.23960/jpmipa/v25i1.p440-452>