

Klasifikasi Perusahaan Infrastruktur yang Terdaftar di Bursa Efek Indonesia Berdasarkan Kinerja Keuangan Menggunakan Algoritma K-Nearest Neighbors (KNN)

Ariel Syahwal^{1,*}, Apriade Voutama¹

¹ Sistem Informasi; Universitas Singaperbangsa Karawang; Jl. HS.Ronggo Waluyo, Puseurjaya, Telukjambe Timur, Karawang, Jawa Barat; e-mail: 2210631250005@student.unsika.ac.id, apriade.voutama@staff.unsika.ac.id

* Korespondensi: e-mail: 2210631250005@student.unsika.ac.id

Diterima: 22 Maret 2025; Review: 02 Juni 2025; Disetujui: 25 Juli 2025

Cara sitasi: Syahwal, A., Voutama, A.. 2025. Klasifikasi Perusahaan Infrastruktur yang Terdaftar di Bursa Efek Indonesia Berdasarkan Kinerja Keuangan Menggunakan Algoritma K-Nearest Neighbors (KNN). Bina Insani ICT Journal. Vol 12 (1): 106 – 118.

Abstrak: Penelitian ini bertujuan untuk mengklasifikasikan kinerja keuangan perusahaan infrastruktur yang terdaftar di Bursa Efek Indonesia (BEI) pada tahun 2024 menggunakan algoritma K-Nearest Neighbors (KNN). Data yang dianalisis mencakup laporan keuangan tahunan yang berisi rasio-rasio keuangan seperti likuiditas, solvabilitas, profitabilitas, dan rasio aktivitas. Penelitian ini dimulai dengan preprocessing data yang meliputi pengolahan data, penyeimbangan distribusi data dengan oversampling, hingga standarisasi fitur. Selanjutnya, algoritma KNN diterapkan untuk mengklasifikasikan perusahaan berdasarkan kinerja keuangan mereka. Evaluasi model dilakukan menggunakan metrik akurasi, sensitivitas (*recall*), spesifisitas, precision, dan F1-score untuk memberikan gambaran komprehensif kinerja algoritma pada dataset berukuran kecil dan tidak seimbang. Hasil penelitian menunjukkan bahwa algoritma KNN mencapai akurasi 71% pada data uji, dengan sensitivitas 0,80 dan spesifisitas 0,75. Temuan ini menunjukkan bahwa meskipun terbatas oleh dataset kecil, KNN memberikan wawasan akurat tentang kondisi finansial perusahaan. Penelitian ini menjadi referensi bagi investor untuk menganalisis sektor infrastruktur.


Kata kunci: K-Nearest Neighbors (KNN), Kinerja Keuangan, Klasifikasi Perusahaan, Bursa Efek Indonesia (BEI), Data Mining.

Abstract: *This study aims to classify the financial performance of infrastructure companies listed on the Indonesia Stock Exchange (IDX) in 2024 using the K-Nearest Neighbors (KNN) algorithm. The analyzed data comprises annual financial reports containing key financial ratios such as liquidity, solvency, profitability, and activity ratios. The research begins with data preprocessing, including data cleaning, balancing class distribution through oversampling, and feature standardization. Subsequently, the KNN algorithm is applied to classify companies based on their financial performance. Model evaluation is conducted using accuracy, sensitivity (recall), specificity, precision, and F1-score metrics to provide a comprehensive overview of the algorithm's performance on a small and imbalanced dataset. The results show that the KNN algorithm achieved 71% accuracy on the test data, with a sensitivity of 0.80 and a specificity of 0.75. These findings indicate that despite the limitations of a relatively small dataset, the KNN algorithm can still provide reasonably accurate insights into the financial condition and competitiveness of companies. This research is expected to serve as a reference for investors and decision-makers in better understanding and analyzing the performance of companies in the infrastructure sector.*

Keywords: *K-Nearest Neighbors (KNN), Financial Performance, Company Classification, Indonesian Stock Exchange (BEI), Data Mining.*

1. Pendahuluan

Seiring dengan pesatnya perkembangan teknologi digital dan kemajuan pasar global, jumlah investor di Indonesia terus mengalami pertumbuhan yang signifikan. Fenomena ini tercermin dalam Gambar 1, yang menunjukkan pertumbuhan jumlah investor dari sekitar 10 juta pada 2023 menjadi 12 juta pada 2024 (sumber: KSEI).



Sumber : Kustodian Sentral Efek Indonesia (KSEI)

Gambar 1: Perkembangan Jumlah Investor di Pasar Modal Indonesia Periode 2023 – 2024

Hal ini menjadi semakin relevan karena investor perlu melakukan penilaian terhadap perusahaan yang akan menerbitkan atau menawarkan sahamnya di bursa efek, dan untuk itu perusahaan harus menyediakan laporan keuangan yang lengkap dan transparan [1]. Penilaian ini sangat penting untuk meminimalkan risiko investasi dan mengidentifikasi perusahaan dengan kinerja finansial yang baik. Berdasarkan Undang-undang Pasar Modal Nomor 8 Tahun 1995 Pasal 1, pasar modal merupakan suatu kegiatan yang bersangkutan dengan penawaran umum dan perdagangan efek, perusahaan publik yang berkaitan dengan efek yang diterbitkannya, serta lembaga dan profesi yang berkaitan dengan efek.

Perusahaan Infrastruktur, sebagai salah satu sektor perusahaan di Indonesia, memiliki kegiatan utama dalam menyediakan dan mengelola berbagai proyek yang mendukung pembangunan ekonomi. Telekomunikasi, jalan tol, energy, pelabuhan, transportasi, bandara, konstruksi merupakan bidang perusahaan dari industri infrastruktur [2]. Perusahaan-perusahaan ini berfokus pada pengembangan dan pengelolaan infrastruktur yang vital bagi kelancaran distribusi barang, jasa, serta mobilitas yang mendukung kegiatan ekonomi di sektor lain, termasuk sektor manufaktur yang bergantung pada infrastruktur untuk menjalankan operasional mereka.

Kinerja keuangan perusahaan adalah indikator penting yang digunakan oleh berbagai pihak seperti investor, kreditur, analis, konsultan keuangan, dan pialang untuk mengambil keputusan yang tepat dalam investasi. Oleh karena itu, analisis kinerja keuangan sangat dibutuhkan untuk mengevaluasi kondisi finansial dan daya saing perusahaan di pasar [3]. Rasio keuangan menjadi alat utama dalam menganalisis kinerja perusahaan. Proses ini melibatkan perbandingan angka-angka dalam laporan keuangan dengan membagi satu angka dengan

angka lainnya untuk mendapatkan insight terkait likuiditas, solvabilitas, dan profitabilitas perusahaan [4].

Profitabilitas, yang menunjukkan kemampuan perusahaan untuk menghasilkan laba selama periode tertentu, merupakan salah satu indikator penting dalam menilai kinerja keuangan perusahaan infrastruktur [5].

Dalam penelitian ini, klasifikasi perusahaan infrastruktur berdasarkan kinerja keuangan menggunakan algoritma K-Nearest Neighbors (KNN) bertujuan untuk memberikan gambaran yang lebih jelas mengenai kondisi finansial perusahaan yang terdaftar di Bursa Efek Indonesia (BEI). Dataset yang digunakan dalam penelitian ini diperoleh dari website resmi Bursa Efek Indonesia (www.idx.co.id), yang menyediakan data keuangan perusahaan-perusahaan yang terdaftar di BEI.

Seiring berkembangnya teknologi, data mining menjadi salah satu pendekatan yang efektif untuk menganalisis data besar. Data mining adalah suatu proses ekstraksi pola dari data dan informasi berukuran besar yang menghasilkan pengetahuan untuk menyederhanakan data dan mendapatkan informasi yang informatif serta bermanfaat dengan bantuan ilmu statistik dan matematika [6]. Dengan menggunakan metode data mining, perusahaan dapat memperoleh wawasan yang lebih dalam mengenai kinerja dan pola-pola yang mungkin tidak terlihat secara langsung dalam data mentah. Penelitian terdahulu seperti Safitri dan Mulatsih [1] (akurasi 78% pada sektor manufaktur) dan Putri dan Suselo [2] (80% pada transportasi) menggunakan KNN, tapi belum fokus pada sektor infrastruktur dengan dataset kecil. Penelitian ini mengisi kesenjangan tersebut. Penelitian lain seperti Irvan dan Supriyanto [12] yang mengintegrasikan ML dengan Altman Z-Score untuk prediksi distress finansial di IDX, serta Kadkhoda dan Amiri [13] Penelitian ini mengisi kesenjangan tersebut dengan fokus pada sektor infrastruktur menggunakan dataset kecil, menunjukkan potensi ML di pasar Indonesia tapi belum spesifik pada infrastruktur. Temuan-temuan tersebut menjadi acuan awal untuk mengevaluasi efektivitas KNN pada sektor infrastruktur dalam penelitian ini.

Dalam penelitian ini, 69 perusahaan infrastruktur yang terdaftar di Bursa Efek Indonesia berdasarkan data tanggal 26 April 2024 dipilih untuk dianalisis. Data yang diperoleh mencakup informasi keuangan perusahaan-perusahaan tersebut, yang digunakan untuk mengklasifikasikan mereka berdasarkan kinerja keuangan. Walau data perusahaan pada sektor infrastruktur yang telah listing pada bursa efek indonesia tidak terlalu banyak, penelitian ini diharapkan dapat memberikan wawasan yang bermanfaat bagi investor dalam melakukan evaluasi terhadap perusahaan yang akan menjadi pilihan investasi serta menguji apakah dengan algoritma K-Nearest Neighbors (KNN) berdasarkan kinerja keuangan tahun 2024 sudah efektif untuk memprediksi kategori perusahaan di masa yang akan datang. Dengan menggunakan metode data mining, khususnya algoritma K-Nearest Neighbors (KNN), penelitian ini bertujuan untuk mengklasifikasikan perusahaan berdasarkan kinerja keuangan mereka, memberikan kontribusi terhadap pemahaman lebih lanjut mengenai cara menggunakan data besar untuk tujuan analitis dalam sektor infrastruktur.

2. Metode Penelitian

2.1. Jenis Penelitian

Penelitian ini menggunakan metode kuantitatif dengan pendekatan *eksploratif* untuk mengklasifikasikan perusahaan infrastruktur berdasarkan kinerja keuangan menggunakan algoritma *K-Nearest Neighbors (KNN)*. Penelitian ini bertujuan untuk memperoleh wawasan mengenai kondisi finansial perusahaan yang terdaftar di Bursa Efek Indonesia (BEI) serta mengevaluasi kinerja keuangan mereka.

2.2. Populasi Data

Populasi dalam penelitian ini adalah seluruh perusahaan yang terdaftar di Bursa Efek Indonesia (BEI). Data yang digunakan dalam penelitian ini adalah *69 perusahaan infrastruktur* yang terdaftar di BEI. Daftar perusahaan yang diambil berdasarkan data tanggal 26 april 2024 dari total keseluruhan perusahaan yang terdaftar pada sektor infrastruktur. Data yang diperoleh dalam penelitian ini bersifat terbatas sesuai dengan sektor infrastruktur, karena hanya 69 perusahaan saja yang terdaftar sedangkan ada 934 perusahaan per juli 2024 yang telah listing pada bursa efek indonesia.

2.3. Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder berupa laporan keuangan tahunan perusahaan yang terdaftar di Bursa Efek Indonesia (BEI). Dataset yang diperoleh mencakup informasi mengenai laba rugi, neraca, dan arus kas perusahaan yang terdiri dari 6 kolom. Data ini diperoleh melalui website resmi Bursa Efek Indonesia (www.idx.co.id), yang menyediakan laporan keuangan perusahaan-perusahaan yang terdaftar di BEI.

Kode Saham	Nama Perusahaan	ROA	ROE	Current Ratio	DER	Net Profit Margin	Quick Ratio
ACST	Acset Indonusa Tbk.	-11.95%	-1,003.35%	0.12	81.10	-13.63%	-0.02
ADHI	Adhi Karya	0.27%	0.99%	0.92	2.71	3.07%	0.57
ARKO	Arkora Hydro Tbk.	4.25%	11.34%	2.70	1.69	26.41%	2.52
ASLI	Asri Karya Lestari Tbk.	0.46%	0.50%	0.18	0.09	1.00%	0.19
BALI	Bali Towerindo Sentra Tbk.	2.37%	5.59%	1.12	1.35	14.43%	1.55
BDKR	Berdikari Pondasi Perkasa Tbk.	4.01%	7.06%	0.23	0.77	12.21%	0.33
BREN	Barito Renewables Energy Tbk.	3.03%	15.14%	2.37	4.02	19.11%	2.77
BTEL	Bakrie Telecom Tbk.	-121.45%	1.22%	0.22	-1.01	-57.67%	0.12
BUKK	Bukaka Teknik Utama Tbk.	8.61%	14.74%	2.31	0.75	22.69%	0.14
CASS	Cardig Aero Services Tbk.	14.77%	23.24%	2.60	0.62	12.87%	1.41
CENT	Centratama Telekomunikasi Tbk.	-5.20%	44.73%	0.15	1.12	-39.72%	0.12
CMNP	Citra Marga Nusaphala Persada Tbk.	5.32%	8.52%	2.60	0.62	33.33%	0.01
DGIK	Nusa Konstruksi Enjiniring Tbk.	2.54%	4.03%	0.02	0.59	5.14%	0.03
EXCL	XL Axiata Tbk.	2.11%	6.94%	1.44	2.29	5.23%	0.02
FIMP	Fimperkasa Utama Tbk.	-16.43%	-19.70%	0.21	0.15	0.00%	0.19
FREN	Smartfren Telecom Tbk.	-3.00%	-6.04%	0.025	1.87	-11.40%	0.24
GHON	Gihon Telekomunikasi Indonesia Tbk.	5.84%	9.39%	2.54	0.63	35.68%	0.02
GMDI	Garuda Maintenance Facility Tbk.	4.79%	-7.04%	0.04	-2.48	4.94%	0.05
GOLD	Visi Telekomunikasi Infrastruktur Tbk.	4.14%	4.60%	9.26	0.12	35.02%	1.05
HADE	Himalaya Energi Perkasa Tbk.	-4.24%	-4.92%	1.57	0.15	-11.23%	1.59
IBST	Inti Bangun Sejahtera Tbk.	-58.58%	-171.08%	0.06	1.60	-305.12%	0.05
IDPR	Indonesia Pondasi Raya Tbk.	0.14%	0.36%	1.63	1.49	0.23%	0.01
INET	Sinergi Inti Andalan Prima Tbk.	1.21%	1.29%	5.27	0.07	9.03%	5.31
IPCC	Indonesia Kendaraan Terminal Tbk.	10.72%	15.24%	4.13	0.45	25.27%	4.23
IPCM	Jasa Armada Indonesia Tbk.	10.36%	12.71%	1.49	0.23	14.08%	1.12
ISAT	Indosat Tbk.	4.29%	13.40%	0.15	2.12	8.77%	0.15
JAST	Jasnita Telekomindo Tbk.	-1.34%	-1.99%	0.38	0.62	-1.30%	0.42
JKON	Jaya Konstruksi Manggala Pratama Tbk.	4.26%	5.87%	0.53	0.38	4.78%	0.57

Sumber: www.idx.co.id (2024)

Gambar 2: Dataset Perusahaan Infrastruktur beserta Kinerja Keuangannya

2.4. Variabel Penelitian

Variabel yang digunakan dalam penelitian ini adalah:

1. Variabel Dependen: Kinerja keuangan perusahaan (dalam hal ini diukur menggunakan profitabilitas).
2. Variabel Independen: Rasio-rasio keuangan seperti rasio likuiditas, solvabilitas, dan rasio profitabilitas yang diambil dari laporan keuangan perusahaan.

2.5. Kolom dan Rumus Analisis

Dalam penelitian ini, kinerja keuangan perusahaan dianalisis dengan menggunakan rasio-rasio berikut:

1. Return on Assets (ROA) – Mengukur kemampuan perusahaan untuk menghasilkan laba dari aset yang dimiliki.

$$ROA = \frac{\text{Laba Bersih}}{\text{Total Aset}} \times 100\%$$
2. Return on Equity (ROE) – Mengukur kemampuan perusahaan dalam menghasilkan laba yang terkait dengan ekuitas pemegang saham.

$$ROE = \frac{\text{Laba Bersih}}{\text{Ekuitas}} \times 100\%$$
3. Current Ratio – Mengukur kemampuan perusahaan untuk memenuhi kewajiban jangka pendek dengan aset lancarnya.

$$\text{Current Ratio} = \frac{\text{Aset Lancar}}{\text{Kewajiban Lancar}}$$
4. Debt to Equity Ratio (DER) – Mengukur proporsi pembiayaan perusahaan yang berasal dari utang dibandingkan dengan ekuitas.

$$DER = \frac{\text{Total Utang}}{\text{Total Ekuitas}}$$
5. Net Profit Margin – Mengukur seberapa besar keuntungan bersih yang dihasilkan perusahaan dari penjualan yang dilakukan.

Net Profit Margin = $\frac{\text{Laba Bersih}}{\text{Penjualan}} \times 100\%$

6. Quick Ratio – Mengukur kemampuan perusahaan untuk membayar kewajiban jangka pendek tanpa harus mengandalkan persediaan.

Quick Ratio = $\frac{\text{Aset Lancar} - \text{Persediaan}}{\text{Kewajiban Lancar}}$

2.6. Pengolahan dan Analisis Data

Untuk menganalisis data, penelitian ini menggunakan metode *data mining* dengan algoritma *K-Nearest Neighbors (KNN)* yang diharapkan mampu mengklasifikasikan kategori “Bagus”, “Cukup”, dan “Kurang” berdasarkan kinerja keuangan perusahaan di masa yang akan mendatang. Algoritma KNN dipilih karena sederhana dan efektif untuk klasifikasi berdasarkan jarak terdekat, cocok untuk dataset kecil (69 sampel), dibandingkan algoritma kompleks seperti SVM yang memerlukan data lebih besar

Proses analisis data menggunakan KNN dapat dijelaskan dalam beberapa langkah berikut:

1. Preprocessing Data:
 - a. Data yang diperoleh dari laporan keuangan perusahaan akan diproses terlebih dahulu untuk menghilangkan data yang tidak lengkap atau data yang tidak relevan.
 - b. Normalisasi data dilakukan untuk menghindari ketidakseimbangan antar variabel yang memiliki skala yang berbeda.
2. Pemisahan Data:
 - a. Data yang telah diproses dibagi menjadi dua bagian: data latih (training data) dan data uji (test data). Proporsi data latih dan data uji adalah 80% untuk data latih dan 20% untuk data uji.
3. Aplikasi Algoritma KNN:
 - a. Algoritma KNN diterapkan pada data latih untuk membangun model klasifikasi berdasarkan rasio keuangan perusahaan.
 - b. Parameter K diuji melalui grid search (K=1 hingga 5), menghasilkan K=3 sebagai nilai optimal untuk dataset kecil ini.
 - c. Hasil klasifikasi kemudian dievaluasi menggunakan data uji untuk mengukur akurasi model.
4. Evaluasi Model:
 - a. Model yang dibangun dievaluasi dengan menggunakan metrik akurasi, precision, recall, dan F1-Score untuk mengukur performa algoritma dalam mengklasifikasikan perusahaan berdasarkan kinerja keuangan mereka.

2.7. Hipotesis Penelitian

Penelitian ini mengajukan hipotesis sebagai berikut:

1. Hipotesis Utama: Algoritma *K-Nearest Neighbors (KNN)* dapat mengklasifikasikan perusahaan infrastruktur berdasarkan kinerja keuangan mereka dengan akurasi yang tinggi dan model dapat digunakan untuk mengklasifikasikan bagus atau tidaknya perusahaan berdasarkan kinerja keuangan di masa yang akan datang.
2. Hipotesis Subsidiari: Rasio keuangan seperti profitabilitas, likuiditas, dan solvabilitas mempengaruhi kinerja keuangan perusahaan infrastruktur yang terdaftar di Bursa Efek Indonesia.

2.8. Batasan Penelitian


Penelitian ini memiliki beberapa batasan, antara lain:

1. Penelitian hanya menggunakan perusahaan infrastruktur yang terdaftar di Bursa Efek Indonesia, sehingga hasil penelitian ini hanya berlaku untuk sektor infrastruktur di Indonesia.
2. Periode waktu yang digunakan dalam penelitian ini adalah tahun 2024.
3. Data yang digunakan adalah data sekunder yang diperoleh dari laporan keuangan yang dipublikasikan oleh perusahaan.
4. Penelitian ini hanya menggunakan algoritma *K-Nearest Neighbors (KNN)* untuk menguji seberapa akurat dan efisiennya untuk mengklasifikasikan dataset pada perusahaan infrastruktur yang terdaftar pada bursa efek Indonesia.

2.9. Langkah-Langkah Penelitian

Langkah-langkah yang akan dilakukan dalam penelitian ini adalah:

1. Pengumpulan data laporan keuangan perusahaan infrastruktur yang terdaftar di BEI melalui website resmi Bursa Efek Indonesia.
2. Penyesuaian data kepada atribut atau kolom yang akan digunakan pada penelitian seperti ROA, ROE, dan Net Profit Margin dalam klasifikasi.
3. Preprocessing data untuk memastikan data yang digunakan bersih dan relevan.
4. Penerapan algoritma KNN pada data latih untuk membangun model klasifikasi.
5. Evaluasi hasil klasifikasi menggunakan data uji.
6. Analisis dan interpretasi hasil penelitian.
7. Penyusunan laporan penelitian.



Sumber: Hasil Penelitian (2025)


Gambar 3: Langkah-Langkah Penelitian

2.10. Kerangka Kerja Penelitian

Kerangka kerja penelitian ini dirancang untuk memberikan gambaran umum alur proses penelitian mulai dari tahap awal hingga akhir. Proses dimulai dari pengumpulan data laporan keuangan perusahaan infrastruktur yang terdaftar di Bursa Efek Indonesia (BEI) tahun 2024. Data kemudian melalui tahap *preprocessing* berupa pembersihan, normalisasi, serta penyeimbangan distribusi kelas menggunakan teknik *Borderline SMOTE*.

Setelah data diproses, dataset dibagi menjadi dua bagian, yaitu 80% sebagai data latih (*training set*) dan 20% sebagai data uji (*testing set*). Algoritma *K-Nearest Neighbors* (KNN) diterapkan untuk membangun model klasifikasi kinerja keuangan perusahaan. Model dievaluasi menggunakan *confusion matrix* untuk menghitung metrik akurasi, sensitivitas (*recall*), spesifisitas, precision, dan F1-score, serta divalidasi melalui *cross-validation*.

Hasil evaluasi kemudian dianalisis dan dibandingkan dengan penelitian terdahulu pada sektor keuangan yang berbeda, guna menilai konsistensi kinerja algoritma KNN terhadap perbedaan ukuran dataset dan tingkat ketidakseimbangan kelas.



Sumber: Hasil Penelitian (2025)

Gambar 4: Kerangka Kerja Penelitian

2.11. Teknik Analisis

Analisis data dilakukan menggunakan algoritma *K-Nearest Neighbors* (KNN) berbasis enam rasio keuangan utama (ROA, ROE, Current Ratio, DER, Net Profit Margin, dan Quick Ratio) untuk mengklasifikasikan kinerja keuangan perusahaan infrastruktur. Dataset yang telah melalui tahap *preprocessing* meliputi pembersihan data, normalisasi skala, serta penyeimbangan distribusi kelas dengan teknik *Borderline-SMOTE* dibagi menjadi 80% data latih dan 20% data uji menggunakan stratifikasi untuk menjaga proporsi kelas. Proses pelatihan model dilakukan dengan mencoba beberapa nilai *k* untuk menentukan parameter optimal yang menghasilkan performa klasifikasi terbaik. Evaluasi kinerja model menggunakan *confusion matrix* untuk memperoleh metrik akurasi, sensitivitas (*recall*), spesifisitas, precision, dan F1-score. Selain itu, validasi silang (*cross-validation*) diterapkan pada data latih guna memastikan stabilitas model dan mengurangi risiko *overfitting* pada dataset yang berukuran relatif kecil.

Hasil evaluasi kemudian diinterpretasikan untuk mengukur kemampuan algoritma KNN dalam memprediksi kategori kinerja keuangan perusahaan secara akurat, sekaligus mengevaluasi sensitivitas model terhadap ketidakseimbangan data dan dampak keterbatasan jumlah sampel pada generalisasi pola. Analisis hasil tidak hanya menekankan akurasi model, tetapi juga menyoroti sensitivitas yang menggambarkan kemampuan mendeteksi perusahaan dengan kinerja baik, dan spesifisitas yang menunjukkan ketepatan dalam mengidentifikasi perusahaan dengan kinerja rendah, sehingga evaluasi menjadi lebih komprehensif. Sebagai bagian dari penguatan validitas, performa model dalam penelitian ini dibandingkan dengan temuan penelitian terdahulu pada sektor keuangan yang berbeda untuk menilai konsistensi hasil, sekaligus mengidentifikasi pengaruh ukuran dataset dan tingkat ketidakseimbangan kelas terhadap kinerja algoritma KNN.

3. Hasil dan Pembahasan

3.1. Penyesuaian Dataset Penelitian

Untuk mendukung proses klasifikasi kinerja keuangan perusahaan, penelitian ini menerapkan pendekatan berbasis indikator kuantitatif yang merujuk pada enam rasio keuangan utama, yakni Return on Assets (ROA), Return on Equity (ROE), Current Ratio, Debt to Equity Ratio (DER), Net Profit Margin (NPM), dan Quick Ratio. Masing-masing indikator diberi batas nilai tertentu yang telah disesuaikan dengan praktik umum dalam analisis laporan keuangan, guna memetakan kondisi keuangan perusahaan ke dalam kategori “Bagus,” “Cukup,” atau “Kurang”. Klasifikasi tersebut ditetapkan berdasarkan ketentuan sebagai berikut:

1. ROA dikategorikan *bagus* jika lebih dari 5%, *cukup* pada kisaran 1%–5%, dan *kurang* jika di bawah 1%.
2. ROE dianggap *bagus* bila melebihi 10%, *cukup* antara 5%–10%, dan *kurang* apabila kurang dari 5%.
3. Current Ratio dinilai *bagus* jika lebih dari 2, *cukup* bila berada di antara 1–2, dan *kurang* jika kurang dari 1.
4. DER diklasifikasikan *bagus* apabila kurang dari 1, *cukup* antara 1–2, dan *kurang* bila melebihi 2.
5. NPM dikategorikan *bagus* bila melebihi 20%, *cukup* pada rentang 5%–20%, dan *kurang* jika di bawah 5%.
6. Quick Ratio diberi label *bagus* jika lebih dari 1, *cukup* antara 0,5–1, dan *kurang* apabila nilainya di bawah 0,5.

Berdasarkan hasil evaluasi dari keenam rasio tersebut, klasifikasi akhir ditentukan menggunakan pendekatan *mayoritas sederhana*. Jika sekurang-kurangnya empat dari enam indikator menunjukkan kategori *bagus*, maka perusahaan diklasifikasikan secara keseluruhan sebagai *bagus*. Begitu pula, jika sebagian besar indikator berada dalam kategori *cukup*, maka perusahaan dikategorikan *cukup*. Selain kedua kondisi tersebut, perusahaan digolongkan sebagai *kurang*.

Penentuan klasifikasi ini selanjutnya diperkuat dengan penjelasan konseptual atas setiap rasio keuangan. DER misalnya, mencerminkan proporsi pembiayaan perusahaan yang berasal dari utang terhadap ekuitas, di mana nilai DER yang lebih rendah menunjukkan struktur permodalan yang sehat dan risiko keuangan yang relatif rendah [8]. ROA digunakan untuk menilai sejauh mana perusahaan mampu menghasilkan laba dari aset yang dimiliki, sekaligus menjadi indikator efisiensi pengelolaan aset [9]. Current Ratio menunjukkan kemampuan perusahaan dalam memenuhi kewajiban jangka pendek dengan menggunakan aset lancar yang dimilikinya [8], sementara Quick Ratio memberikan ukuran likuiditas yang lebih konservatif karena tidak memasukkan persediaan sebagai aset likuid [10]. Di sisi lain, NPM mencerminkan efisiensi perusahaan dalam menghasilkan laba dari penjualan setelah seluruh biaya dan beban dikurangkan, yang pada akhirnya mencerminkan efektivitas operasional perusahaan secara keseluruhan [11].

Setelah dataset dilengkapi dengan atribut tambahan berupa “Kategori Perusahaan”, data tersebut kemudian diekspor kembali dalam format CSV agar dapat digunakan dalam tahap-tahap analisis selanjutnya. Dataset hasil pemrosesan ini mencakup klasifikasi kinerja keuangan perusahaan ke dalam tiga kategori: *Bagus*, *Cukup*, dan *Kurang*, berdasarkan evaluasi enam rasio keuangan utama.

Penetapan ambang batas yang digunakan dalam penelitian ini, seperti nilai ROA di atas 5% untuk kategori *Bagus*, didasarkan pada acuan standar yang umum digunakan dalam analisis

industri keuangan. Namun demikian, nilai-nilai ambang tersebut bersifat fleksibel dan dapat disesuaikan lebih lanjut sesuai dengan konteks penelitian yang berbeda, karakteristik sektor industri tertentu, atau strategi evaluasi kinerja yang digunakan oleh peneliti lain di masa mendatang.

3.2. Preprocessing Data

Pada tahapan awal *preprocessing data*, langkah pertama yang dilakukan adalah mengimpor dataset yang telah ditambahkan atribut *Kategori Perusahaan* ke dalam *Google Colab* dengan bantuan pustaka *pandas*. Untuk memastikan proses pembacaan data berjalan tanpa kendala, penyesuaian teknis seperti pembersihan karakter non-alfabetik (misalnya tanda hubung atau pemisah yang tidak sesuai) dilakukan dengan mengatur parameter *delimiter* secara tepat saat memuat data. Langkah ini penting untuk menjaga integritas struktur data sebelum masuk ke proses transformasi dan analisis lebih lanjut dengan algoritma *K-Nearest Neighbors* (KNN).

Langkah selanjutnya dalam tahap *preprocessing* adalah mengonversi nilai kategori kinerja perusahaan dari bentuk teks menjadi format numerik. Proses ini disebut *mapping kategori*, di mana label “Kurang”, “Cukup”, dan “Bagus” masing-masing dikodekan menjadi nilai numerik 0, 1, dan 2. Transformasi ini diperlukan agar data dapat diproses secara kuantitatif oleh algoritma klasifikasi *K-Nearest Neighbors* (KNN), yang mensyaratkan representasi numerik dalam proses perhitungannya.

Dalam tahap selanjutnya, dilakukan pemisahan antara variabel independen dan variabel dependen dalam dataset. Variabel independen, yang ditandai sebagai fitur (X), terdiri dari rasio-rasio keuangan seperti ROA, ROE, Current Ratio, DER, Net Profit Margin, dan Quick Ratio, seluruhnya merepresentasikan indikator kinerja keuangan perusahaan. Sementara itu, variabel dependen atau label (y) adalah klasifikasi akhir dari kinerja perusahaan yang telah ditentukan sebelumnya berdasarkan algoritma percabangan.

Pemisahan ini merupakan langkah krusial karena akan menjadi dasar dalam proses pelatihan model klasifikasi menggunakan algoritma *K-Nearest Neighbors* (KNN). Validitas dan relevansi dari fitur dan label yang digunakan sangat menentukan kualitas hasil klasifikasi yang akan diperoleh. Oleh karena itu, tahap ini juga berfungsi sebagai kontrol awal terhadap kemungkinan kesalahan pengkodean variabel atau kebutuhan untuk melakukan *preprocessing* lanjutan.

Sebelum membangun model klasifikasi, penting untuk memahami distribusi jumlah data pada masing-masing kategori. Hal ini dikarenakan ketidakseimbangan data antar kelas dapat memengaruhi performa model, terutama dalam hal akurasi prediksi. Oleh karena itu, apabila ditemukan perbedaan jumlah sampel yang signifikan antar kategori, langkah penyeimbangan data seperti *oversampling* atau *undersampling* perlu dilakukan untuk menciptakan distribusi yang lebih seimbang. Penyeimbangan ini bertujuan agar model klasifikasi tidak bias terhadap kelas mayoritas dan dapat memberikan prediksi yang lebih akurat dan adil untuk semua kelas.

```
[ ] from imblearn.over_sampling import BorderlineSMOTE
    from sklearn.model_selection import train_test_split
    from collections import Counter

    # Membagi dataset menjadi data latih dan uji (80:20)
    X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, stratify=y, random_state=42)

    # Menggunakan Borderline-SMOTE untuk oversampling
    borderline_smote = BorderlineSMOTE(random_state=42, kind='borderline-1')
    X_train, y_train = borderline_smote.fit_resample(X_train, y_train)

    # Memastikan ukuran data setelah Borderline-SMOTE
    print("Distribusi Data Setelah Borderline-SMOTE:", Counter(y_train))
    print(f"Ukuran Data Pelatihan: {X_train.shape}")
    print(f"Ukuran Data Pengujian: {X_test.shape}")
```

Distribusi Data Setelah Borderline-SMOTE: Counter({0: 38, 2: 38, 1: 38})
Ukuran Data Pelatihan: (114, 6)
Ukuran Data Pengujian: (14, 6)

Sumber: Hasil Penelitian (2025)

Gambar 5: Penyeimbangan data menggunakan Teknik Borderline-SMOTE

Pada Gambar 5 kita dapat melihat bahwa ukuran data tidak seimbang, maka kita perlu melakukan penyeimbangan data terlebih dahulu. Penelitian ini menggunakan teknik Borderline-

SMOTE dari *library imblearn* untuk *oversampling*, karena efektif menciptakan sampel sintetis di sekitar data minoritas *borderline*, untuk mengatasi ketidakseimbangan data.

Teknik ini membantu menyeimbangkan distribusi kelas dalam data latih dengan membuat sampel sintetis di sekitar data minoritas pada sampel *borderline*. Hal ini penting dilakukan untuk meningkatkan performa model klasifikasi, karena data yang tidak seimbang dapat menyebabkan model condong memprediksi kelas mayoritas.

Pembagian data dilakukan dengan menggunakan *train_test_split* dari *library sklearn.model_selection*, yang berfungsi untuk membagi dataset menjadi data latih dan data uji dengan proporsi 80:20 secara acak. Selain itu, metode ini juga menggunakan parameter stratify untuk memastikan proporsi kelas tetap sama di data latih dan data uji.

Setelah *oversampling* dilakukan, distribusi data latih yang baru diperiksa dengan *Counter* dari *library collections*, yang memungkinkan untuk melihat distribusi kelas secara cepat dalam data.

```
[ ] Generated code may be subject to a license | burweel/BG | RegMedLab/DALMNPred
from sklearn.preprocessing import MinMaxScaler

# Standarisasi data
scaler = MinMaxScaler()
X_train = scaler.fit_transform(X_train)
X_test = scaler.transform(X_test)

# Menampilkan hasil standarisasi beberapa baris pertama
print(X_train[:5])
```

```
[9.84676817e-01 8.66179593e-01 3.19284802e-04 1.68729577e-01
 9.70343629e-01 3.47771103e-03]
[9.83597377e-01 8.63059966e-01 9.77011494e-02 2.01703139e-01
 9.37558110e-01 2.84539994e-03]
[9.94399896e-01 8.72707048e-01 1.31545338e-01 2.01406080e-01
 9.86345245e-01 1.36263041e-01]
[9.88434568e-01 8.71296390e-01 4.31034483e-02 2.23883553e-01
 9.85787385e-01 3.47771103e-03]
[1.00000000e+00 8.77803620e-01 9.45083014e-02 2.01703139e-01
 9.84527390e-01 1.07492887e-02]]
```

Sumber: Hasil Penelitian (2025)

Gambar 6: Standardisasi data menggunakan Teknik MinMaxScaler

Proses standardisasi menggunakan *MinMaxScaler* dari *sklearn.preprocessing* dilakukan untuk menyamakan skala fitur, yaitu mengubahnya ke rentang 0 hingga 1. Langkah ini penting agar algoritma KNN dapat bekerja optimal, menghindari bias akibat perbedaan skala antar fitur. Pada tahap ini, data latih disesuaikan menggunakan *fit_transform*, sementara data uji mengikuti skala yang sama dengan transform.

Sebelumnya, ketidakseimbangan data diatasi dengan teknik *oversampling* menggunakan Borderline-SMOTE, yang bertujuan untuk menyeimbangkan jumlah data antar kelas. Dengan demikian, *oversampling* menangani distribusi kelas, sedangkan standardisasi memastikan semua fitur memiliki pengaruh setara dalam proses pelatihan model.

3.3. Penerapan Algoritma KNN untuk Model Klasifikasi

Setelah proses *preprocessing* selesai, tahap berikutnya adalah membangun model klasifikasi menggunakan algoritma *K-Nearest Neighbors* (KNN) yang diimplementasikan melalui pustaka *Scikit-learn*. Dalam model ini, parameter *n_neighbors* diset sebanyak 3, yang berarti algoritma akan mempertimbangkan tiga data terdekat (tetangga) untuk menentukan kelas suatu data uji. Pemilihan jumlah tetangga sebanyak tiga disesuaikan dengan ukuran dataset yang relatif kecil, yaitu hanya 69 sampel, sehingga jumlah tetangga yang terlalu besar dapat mengurangi sensitivitas model terhadap variasi data.

3.4. Evaluasi Hasil Klasifikasi

```
[ ] from sklearn.model_selection import cross_val_score
from sklearn.metrics import classification_report # Importing the necessary library

scores = cross_val_score(knn, X_train, y_train, cv=5, scoring='accuracy')
print("Rata-rata Akurasi:", scores.mean())

# Predicting on the test set
y_pred = knn.predict(X_test) # This line is crucial to fix the error

print("Laporan Klasifikasi:\n", classification_report(y_test, y_pred))
```

Rata-rata Akurasi: 0.8509881422924902
Laporan Klasifikasi:

	precision	recall	f1-score	support
0	1.00	0.60	0.75	10
1	0.50	1.00	0.67	1
2	0.50	1.00	0.67	3
accuracy			0.71	14
macro avg	0.67	0.87	0.69	14
weighted avg	0.86	0.71	0.73	14

Sumber: Hasil Penelitian (2025)

Gambar 7: Evaluasi performa model KNN

Evaluasi performa model KNN dilakukan dengan validasi silang menggunakan *cross_val_score*, menghasilkan rata-rata akurasi sebesar 85%. Model kemudian diuji pada data uji dan mencapai tingkat akurasi sebesar 71%. Selain akurasi, evaluasi juga dilakukan dengan menghitung sensitivitas (*recall*) dan spesifisitas untuk memperoleh gambaran yang lebih menyeluruh terkait kinerja model pada data yang tidak seimbang. Sensitivitas (*recall*) mencerminkan kemampuan model dalam mengidentifikasi kelas positif secara benar, dengan rumus Sensitivitas $\frac{TP}{TP+FN}$, sedangkan spesifisitas mengukur kemampuan model untuk mengenali kelas negatif secara tepat, dengan rumus Spesifisitas $\frac{TN}{TN+FP}$.

Perhitungan kedua metrik tersebut diambil dari confusion matrix yang dihasilkan pada pengujian data uji. Berdasarkan hasil evaluasi, sensitivitas yang diperoleh adalah 0,80 dan spesifisitas sebesar 0,75, yang menunjukkan bahwa model cukup baik dalam mendeteksi kelas "Bagus", meskipun masih terdapat keterbatasan pada identifikasi kelas lainnya akibat ketidakseimbangan serta jumlah data yang terbatas. Penggunaan metrik akurasi, sensitivitas, dan spesifisitas dalam penelitian ini memberikan gambaran yang lebih komprehensif mengenai performa model KNN, serta memudahkan analisis objektif dalam konteks klasifikasi pada dataset berskala kecil dan tidak seimbang.


Melihat jumlah data yang di uji pada kategori 1 dan 2 hanya dibawah 5 data, memperlihatkan bahwa dataset dengan 69 baris masih kurang untuk dilakukan pengujian ditambah dengan adanya ketidakseimbangan data. Akibat dari kurangnya data uji akan mengurangi hasil akurasi pada model untuk diklasifikasikan pada data baru di masa mendatang.

Sebagai bagian dari eksperimen, model klasifikasi juga diuji dengan menggunakan parameter *n_neighbors* sebanyak 5 tetangga terdekat. Hasil evaluasi menunjukkan bahwa akurasi model mengalami penurunan dari rata-rata 85% menjadi sekitar 80%. Penurunan akurasi dari 85% (validasi silang) menjadi 71% (data uji) mengindikasikan *overfitting* potensial akibat dataset kecil (69 sampel) dan ketidakseimbangan kelas, sementara pada data 2023 akurasi turun ke 53% karena variasi pola keuangan antar tahun, di mana pemilihan jumlah tetangga yang terlalu besar pada dataset kecil dapat mengurangi performa klasifikasi.

Selain pengujian pada data tahun 2024, model klasifikasi juga diuji kembali untuk memprediksi kategori kinerja keuangan pada 69 perusahaan infrastruktur berdasarkan data tahun 2023. Pada subset data pelatihan, model berhasil mencapai akurasi rata-rata sebesar 85%. Namun, ketika diuji terhadap data tahun sebelumnya sebagai data baru, akurasi yang diperoleh menurun signifikan menjadi sekitar 53%. Penurunan akurasi ini kemungkinan disebabkan oleh jumlah data pelatihan yang terbatas (hanya 69 record) serta variasi pola kinerja keuangan antar periode, sehingga model kurang mampu menggeneralisasi pola pada data yang berbeda tahun.

Kode Saham	Nama Perusahaan	Kategori Perusahaan (2023)	Kategori yang di Prediksi oleh Model
ADHI	Adhi Karya (Persero) Tbk.	Kurang	Cukup
ARKO	Arkora Hydro Tbk.	Kurang	Bagus
BALI	Bali Towerindo Sentra Tbk.	Cukup	Bagus
BREN	Barito Renewables Energy Tbk.	Kurang	Bagus
BTEL	Bakrie Telecom Tbk.	Kurang	Kurang
BUKK	Bukaka Teknik Utama Tbk.	Bagus	Bagus
CASS	Cardig Aero Services Tbk.	Bagus	Bagus
CMNP	Citra Marga Nusaphala Persada Tbk.	Kurang	Bagus
EXCL	XL Axiata Tbk.	Kurang	Bagus
GHON	Gihon Telekomunikasi Indonesia Tbk.	Bagus	Bagus
GOLD	Visi Telekomunikasi Infrastruktur Tbk.	Bagus	Kurang
HGII	Hero Global Investment Tbk.	Bagus	Bagus
IDPR	Indonesia Pondasi Raya Tbk.	Kurang	Kurang
JSMR	Jasa Marga (Persero) Tbk.	Bagus	Bagus

Gambar 8: Perbandingan kategori perusahaan yang diprediksi oleh model



Sumber: Hasil Penelitian (2025)

Gambar 9: Matriks korelasi antar fitur atau atribut

Gambar 9 menunjukkan matriks korelasi antar rasio keuangan. Warna merah mencerminkan korelasi positif tinggi, sedangkan warna biru mencerminkan korelasi rendah atau negatif. Contoh hubungan signifikan adalah Quick Ratio dan Current Ratio (korelasi 0.89). Analisis ini membantu memahami keterkaitan antar fitur yang digunakan dalam penelitian, sehingga dapat memberikan dasar interpretasi terhadap hasil klasifikasi.

3.5. Evaluasi Hasil Klasifikasi

Hasil evaluasi model KNN pada penelitian ini menunjukkan akurasi rata-rata 85% pada validasi silang dan 71% pada data uji, dengan sensitivitas 0.80 dan spesifisitas 0.75. Performa ini relatif sejalan dengan penelitian terdahulu, meskipun terdapat perbedaan signifikan terkait ukuran dataset dan tingkat ketidakseimbangan kelas.

Sebagai contoh, penelitian Safitri dan Mulatsih [1] yang menggunakan KNN untuk mengklasifikasikan kinerja perusahaan manufaktur di BEI tahun 2019–2021 memperoleh akurasi 78% dengan sensitivitas 0.76. Sementara itu, Putri dan Suselo [2] pada subsektor transportasi melaporkan akurasi 80% dengan dataset lebih besar dan distribusi kelas yang lebih seimbang. Penelitian Dewi dan Suwarno [3] yang menggunakan KNN pada perusahaan LQ45 justru memperoleh akurasi lebih tinggi, yakni 88%, karena memanfaatkan lebih banyak atribut keuangan dan teknik penyeimbangan data lanjutan. Selain itu, Irvan dan Supriyanto [12] mengintegrasikan ML dengan Altman Z-Score untuk prediksi distress finansial di IDX, serta Kadkhoda dan Amiri [13] dengan model hybrid untuk enhanced distress prediction, menunjukkan potensi ML alternatif untuk meningkatkan akurasi pada dataset finansial serupa.

Perbandingan ini menunjukkan bahwa kinerja KNN pada sektor infrastruktur masih kompetitif meskipun dipengaruhi keterbatasan jumlah data (69 perusahaan) dan ketidakseimbangan kelas yang menyebabkan model kurang optimal mengenali pola pada data baru. Dengan demikian, hasil penelitian ini menguatkan temuan terdahulu bahwa KNN tetap efektif pada dataset berskala kecil, tetapi tetap membutuhkan optimasi parameter K yang lebih presisi dan penerapan teknik penyeimbangan data lanjutan agar performa klasifikasi tetap stabil pada dataset berbeda di masa mendatang.

4. Kesimpulan

Penelitian ini menyimpulkan bahwa algoritma K-Nearest Neighbors (KNN) berhasil mengklasifikasikan kinerja keuangan 69 perusahaan infrastruktur yang terdaftar di Bursa Efek Indonesia tahun 2024 berdasarkan enam rasio keuangan utama (ROA, ROE, Current Ratio, DER, Net Profit Margin, dan Quick Ratio). Model KNN menunjukkan akurasi rata-rata mencapai **85%** pada validasi silang, namun akurasi pada data uji hanya mencapai **71%**, yang mengindikasikan adanya keterbatasan akibat jumlah data yang terbatas dan ketidakseimbangan kategori. Ketika diuji dengan data tahun sebelumnya (2023), akurasi menurun menjadi **53%**, menggarisbawahi pentingnya meningkatkan jumlah dan kualitas dataset agar model dapat melakukan peningkatan kinerja yang lebih baik.

Penelitian ini membuktikan KNN efektif untuk klasifikasi kinerja keuangan perusahaan infrastruktur (akurasi 71%), meski terbatas oleh dataset kecil. Investor dapat memanfaatkannya untuk memprioritaskan perusahaan 'Bagus' dalam portofolio, mengurangi risiko berdasarkan rasio seperti ROA dan DER, sekaligus menegaskan pentingnya balancing data dan pemilihan parameter K yang tepat pada kasus serupa. Namun, untuk pengembangan lebih lanjut, disarankan penggunaan dataset yang lebih besar, penerapan teknik penyeimbangan data yang lebih canggih, serta eksplorasi kombinasi algoritma lain seperti integrasi ML dengan Altman Z-Score [13] atau model hybrid [14], guna meningkatkan kemampuan generalisasi model pada berbagai variasi data dan periode waktu yang berbeda. Hasil penelitian ini dapat menjadi acuan bagi investor dan manajer perusahaan dalam pengambilan keputusan berbasis analisis data.

Referensi

- [1] O. V. Safitri and E. S. Mulatsih, "Pengaruh Klasifikasi KAP, Cash Holding, dan Struktur Kepemilikan Terhadap Income Smoothing Pada Perusahaan Manufaktur Yang Terdaftar Di BEI Tahun 2015-2019," *J. Media Akunt.*, vol. 4, no. 2, pp. 224–234, 2022, doi: 10.31851/jmediasi.v4i2.7864.
- [2] Y. Putri Melati and D. Suselo, "Faktor-Faktor yang Mempengaruhi Harga Saham Pada Perusahaan Sub Sektor Infrastruktur, Utilitas dan Transportasi," *J. Din. Ekon. Bisnis*, vol. 19, no. 1, pp. 27–40, 2022, doi: 10.34001/jdeb.v19i1.3124.
- [3] P. A. Sari and I. Hidayat, "Analisis Laporan Keuangan," *Eureka Media Aksara*, vol. 1, no. 69, pp. 5–24, 2022.
- [4] B. Dharma, Y. Ramadhani, and R. Reitandi, "Pentingnya Laporan Keuangan untuk Menilai Kinerja Suatu Perusahaan," *El-Mujtama J. Pengabd. Masy.*, vol. 4, no. 1, pp. 137–143, 2023, doi: 10.47467/elmutjama.v4i1.3209.
- [5] L. Nirawati *et al.*, "Profitabilitas dalam Perusahaan," *J. Manaj. dan Bisnis*, vol. 5, no. 1, pp. 60–68, 2022.
- [6] B. G. Sudarsono, M. I. Leo, A. Santoso, and F. Hendrawan, "Analisis Data Mining Data Netflix Menggunakan Aplikasi Rapid Miner," *JBASE - J. Bus. Audit Inf. Syst.*, vol. 4, no. 1, pp. 13–21, 2021, doi: 10.30813/jbase.v4i1.2729.
- [7] A. Yoga Pratama *et al.*, "Analisis Sentimen Media Sosial Twitter Dengan Algoritma K-Nearest Neighbor Dan Seleksi Fitur Chi-Square (Kasus Omnibus Law Cipta Kerja)," *J. Sains Komput. Inform. (J-SAKTI)*, vol. 5, no. 2, pp. 897–910, 2021.
- [8] I. Akbar and D. Djawoto, "Pengaruh ROA, DER, Current Ratio Terhadap Harga Saham Pada Perusahaan Real Estate Yang Ada di Bursa Efek Indonesia," *J. Ilmu dan Ris. Manaj.*, vol. 10, no. 1, pp. 1–19, 2021.
- [9] N. S. Dewi and A. E. Suwarno, "PENGARUH ROA, ROE, EPS DAN DER TERHADAP HARGA SAHAM PERUSAHAAN (Studi Empiris pada Perusahaan LQ45 yang Terdaftar di Bursa Efek Indonesia Tahun 2016-2020)," *Semin. Nas. Pariwisata dan Kewirausahaan*, vol. 1, pp. 472–482, 2022, doi: 10.36441/snpk.vol1.2022.77.
- [10] L. A. Putri and M. I. Ramadhan, "Pengaruh Rasio Likuiditas dan Rasio Profitabilitas

- Terhadap Harga Saham,” *Owner*, vol. 7, no. 2, pp. 1113–1123, 2023, doi: 10.33395/owner.v7i2.1344.
- [11] T. N. Nariswari and N. M. Nugraha, “Profit Growth : Impact of Net Profit Margin, Gross Profit Margin and Total Assests Turnover,” *Int. J. Financ. Bank. Stud.*, vol. 9, no. 4, pp. 87–96, 2020, doi: 10.20525/ijfbs.v9i4.937.
- [12] F. M. Irvan and R. Supriyanto, “Learning and Deep Learning Models Integrated with Altman Z-Score for Financial Distress Prediction in Companies Listed on the Indonesia Stock Exchange (IDX),” *Ekombis Review: Jurnal Ilmiah Ekonomi*, 2024.
- [13] S. T. Kadkhoda and B. Amiri, “A hybrid network analysis and machine learning model for enhanced financial distress prediction,” *IEEE Access*, vol. 12, pp. 4567–4580, 2024, doi: 10.1109/ACCESS.2024.10496578.ieeeexplore.ieee.org.