

Manajemen Proyek ERP Berbasis Nilai: Prediksi Manfaat Menggunakan XGBoost

Fillah Anjany¹, Nurlita Marta Annisa², Muhammad Ainul Yaqin³

¹Teknik Informatika, Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang, 081330727585

²Teknik Informatika, Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang

¹fillahanjany1605@gmail.com ²nurlitamarta28@gmail.com ³yaqinov@ti.uin-malang.ac.id

Abstract

*Enterprise Resource Planning (ERP) implementation is a strategic initiative to improve business process integration and organizational performance; however, many projects that are operationally successful fail to deliver significant business value. This study proposes a **Benefit Realization Prediction in ERP Project Management** approach using a machine learning model based on Extreme Gradient Boosting (XGBoost) with a quantitative explanatory–predictive design and a dataset of 300 ERP projects. The model integrates multi-dimensional variables, including project characteristics, project management, and organizational readiness, to predict benefit realization using a multi-class classification approach. The dataset is split into 80% training data and 20% testing data, where the model is trained to capture complex relationships among variables and evaluated for generalization performance. Hyperparameter tuning is applied to optimize key parameters such as $n_estimators$, $learning_rate$, and max_depth . The results show that the XGBoost model achieves strong performance with an accuracy of 91% and an AUC of 0.95. Feature importance analysis identifies top management support, organizational readiness, project manager experience, user training intensity, and system integration complexity as the most influential factors. Additionally, experimental scenarios such as ablation study and early prediction demonstrate the model's ability to identify key factors and provide early-stage predictions, highlighting its potential as a decision-support tool for proactive and value-based ERP project management.*

Keywords: benefit realization prediction, ERP project management, machine learning, project success prediction, explainable AI

Abstrak

Implementasi *Enterprise Resource Planning* (ERP) merupakan inisiatif strategis untuk meningkatkan integrasi proses bisnis dan kinerja organisasi, namun banyak proyek yang berhasil secara operasional belum mampu menghasilkan nilai bisnis yang optimal. Penelitian ini mengusulkan pendekatan **Benefit Realization Prediction dalam manajemen proyek ERP** menggunakan model *machine learning* berbasis Extreme Gradient Boosting (XGBoost) dengan desain kuantitatif *explanatory–predictive* dan dataset sebanyak 300 proyek ERP. Model yang dikembangkan mengintegrasikan variabel multidimensi yang meliputi karakteristik proyek, manajemen proyek, serta kesiapan organisasi untuk memprediksi tingkat realisasi manfaat menggunakan pendekatan klasifikasi multi-kelas. Dataset dibagi menjadi 80% data pelatihan dan 20% data pengujian, di mana model dilatih untuk mempelajari hubungan kompleks antar variabel dan diuji untuk mengevaluasi kemampuan generalisasi. Proses *hyperparameter tuning* dilakukan untuk mengoptimalkan parameter utama seperti $n_estimators$, $learning_rate$, dan max_depth . Hasil penelitian menunjukkan bahwa model XGBoost memiliki performa yang sangat baik dengan akurasi sebesar 91% dan nilai *Area Under Curve* (AUC) sebesar 0,95. Analisis *feature importance* menunjukkan bahwa dukungan manajemen puncak, kesiapan organisasi, pengalaman manajer proyek, intensitas pelatihan pengguna, serta kompleksitas integrasi sistem merupakan faktor yang paling berpengaruh terhadap realisasi manfaat. Selain itu, skenario eksperimen seperti *ablation study* dan *early prediction* menunjukkan bahwa model

mampu mengidentifikasi faktor kunci serta memberikan prediksi sejak tahap awal proyek, sehingga berpotensi sebagai alat bantu pengambilan keputusan dalam manajemen proyek ERP yang lebih proaktif dan berbasis nilai.

Kata kunci: benefit realization prediction, manajemen proyek ERP, machine learning, prediksi keberhasilan proyek, explainable AI

© 2026 Author

Creative Commons Attribution 4.0 International License



1. Pendahuluan

Implementasi *Enterprise Resource Planning* (ERP) merupakan salah satu langkah strategis yang dilakukan organisasi untuk meningkatkan integrasi proses bisnis, efisiensi operasional, serta kualitas pengambilan keputusan [1] [2]. Sistem ERP memungkinkan berbagai fungsi bisnis dikelola secara terintegrasi dalam satu platform, sehingga mampu meningkatkan transparansi data dan koordinasi antar unit kerja [3]. Namun demikian, tingkat keberhasilan proyek ERP masih menjadi tantangan utama, karena tidak sedikit proyek yang dinyatakan berhasil secara operasional—seperti selesai tepat waktu dan sesuai anggaran—tetapi belum mampu menghasilkan manfaat bisnis (*business value*) yang signifikan [4].

Kondisi tersebut menunjukkan bahwa pengukuran keberhasilan proyek yang hanya berfokus pada indikator tradisional, seperti waktu, biaya, dan ruang lingkup (*triple constraint*), belum mampu merepresentasikan nilai nyata yang dihasilkan oleh proyek [5]. Oleh karena itu, paradigma manajemen proyek modern mulai bergeser menuju pendekatan berbasis nilai (*value-based project management*) yang menekankan pentingnya *benefit realization*

sebagai indikator utama keberhasilan proyek [6]. Dalam konteks ERP, keberhasilan tidak hanya diukur dari sisi implementasi teknis, tetapi juga dari sejauh mana sistem mampu meningkatkan efisiensi proses, menurunkan biaya operasional, serta meningkatkan kualitas dan akurasi informasi [7].

Sejumlah penelitian telah mengkaji keberhasilan implementasi ERP, salah satunya G. Albert (2020) yang menggunakan model DeLone & McLean untuk menganalisis kualitas sistem, informasi, dan layanan terhadap kepuasan pengguna serta *net benefit* ERP [8]. Meskipun memberikan pemahaman terkait faktor keberhasilan dari sisi kualitas dan persepsi pengguna, pendekatan ini masih bersifat deskriptif dan evaluatif, sehingga berfokus pada analisis pasca implementasi, belum mendukung pengambilan keputusan secara proaktif, serta cenderung parsial tanpa mempertimbangkan interaksi kompleks antar dimensi proyek, manajemen, dan organisasi.

Untuk memperjelas posisi penelitian ini, Tabel 1 menyajikan ringkasan studi literatur terkait implementasi ERP dan pendekatan yang digunakan dalam penelitian sebelumnya.

Tabel 1. Ringkasan Studi Literatur Terkait ERP

Sumber	Input yang Dikaji	Metode	Output yang Diharapkan	Hasil Utama
Agarwal (2024)	Data keuangan ERP (penjualan, inventory, demand), Variabel eksternal (market trends)	XGBoost regression	Prediksi penjualan dan kebutuhan sumber daya	XGBoost mampu menangkap hubungan non-linear kompleks dalam ERP dan meningkatkan akurasi forecasting
Pardede et al. (2024)	Data time series (harga cabai), Lag features, faktor eksternal	XGBoost, feature engineering	Prediksi harga	Feature engineering meningkatkan akurasi model
G. Albert (2020)	System Quality, Information Quality, Service Quality,	Model DeLone & McLean IS Success	Tingkat keberhasilan ERP, Nilai net benefit ERP	System quality dan information quality berpengaruh

	Use, User Satisfaction	Model, Analisis kuantitatif (SEM/PLS)		signifikan terhadap kepuasan pengguna
Santoso (2022)	ERP Adoption (kualitas sistem, penggunaan, kemudahan, kepuasan)	Kuantitatif, Analisis: PLS-SEM (SmartPLS 3.0)	ERP berpengaruh signifikan terhadap: Green Purchasing, Green Production, Green Distribution	Manfaat ERP muncul melalui green purchasing & green production
S. Mukherjee (2021)	Pengukuran <i>benefit realization</i> ERP	Kerangka pengukuran manfaat	Model evaluasi manfaat ERP	Fokus pada pengukuran manfaat, belum mengarah pada prediksi
Z. N. Jawad (2024)	Pemanfaatan <i>machine learning</i> pada ERP	Literature review	Potensi ML dalam ERP	ML berpotensi besar, namun belum banyak diterapkan pada prediksi keberhasilan proyek ERP
Z. T. Butarbutar (2023)	Studi ERP pasca implementasi	Systematic Literature Review	Evaluasi keberhasilan ERP	Pendekatan dominan retrospektif dan belum mendukung pengambilan keputusan saat proyek berlangsung

Berdasarkan Tabel 1, dapat diidentifikasi beberapa *research gap*, yaitu: masih terdapat dominasi pendekatan deskriptif dan evaluatif dalam analisis keberhasilan ERP, seperti pada penelitian G.Albert (2020) dan Butarbutar (2023) yang bersifat retrospektif dan berfokus pada evaluasi pasca implementasi [8] [9]. Di sisi lain, meskipun beberapa studi seperti Agarwal (2024) dan Pardede et al. (2024) telah memanfaatkan machine learning (XGBoost) untuk prediksi pada data bisnis, penerapannya dalam konteks ERP khususnya untuk memprediksi benefit realization masih terbatas [10] [11]. Hal ini juga didukung oleh Jawad (2024) yang menyatakan bahwa potensi machine learning dalam ERP besar, namun belum banyak diimplementasikan secara nyata [12].

Urgensi penelitian ini tidak hanya didasarkan pada celah akademik, tetapi juga pada kebutuhan praktis yang mendesak dalam manajemen proyek ERP, yang tercermin dalam tiga hal utama. Pertama, dari sisi mitigasi risiko dan ketidakpastian, proses prediksi memaksa tim untuk mengidentifikasi asumsi dan faktor eksternal yang dapat mempengaruhi hasil, sehingga membantu menyusun rencana kontingensi. Fakta menunjukkan bahwa hanya 1 dari 7 proyek (sekitar 14%) yang berhasil diselesaikan dengan biaya dan waktu di bawah anggaran, sementara sebagian besar penundaan proyek berawal dari sinyal kecil yang tidak terdeteksi hingga masalah membesar. Penerapan analitik prediktif berbasis AI terbukti mampu mengurangi risiko proyek hingga 25% berdasarkan studi kasus empiris. Kedua, dalam hal prioritas portofolio proyek, prediksi manfaat memungkinkan perancangan berdasarkan nilai yang diharapkan

sehingga sumber daya langka dapat dialokasikan ke proyek dengan dampak tertinggi. Namun, rata-rata perusahaan hanya menggunakan 50% dari data yang tersedia saat mengambil keputusan, padahal perusahaan yang berhasil melakukan prioritas berbasis data 2,5 kali lebih mungkin menjadi pemain berkinerja tinggi di industrinya, dan penelitian terbaru menunjukkan bahwa algoritma machine learning mampu memprediksi ROI proyek dengan akurasi tinggi untuk membantu manajer memilih proyek dengan nilai tertinggi. Ketiga, terkait komunikasi dengan pemangku kepentingan, manfaat yang diprediksi dengan jelas membantu menyelaraskan ekspektasi antara sponsor, pengguna, tim, dan pihak lain yang berkepentingan. Menurut Project Management Institute (PMI), jika pemangku kepentingan utama tidak mempersepsikan bahwa hasil proyek berharga, maka proyek tersebut akan dianggap gagal meskipun semua target teknis terpenuhi. Proyek dengan sistem pengukuran kinerja yang jelas memiliki kemungkinan dua kali lipat untuk dianggap sukses oleh para pemangku kepentingan, dan perusahaan yang secara konsisten mengomunikasikan serta memenuhi ekspektasi berbagai pemangku kepentingan menghasilkan imbal hasil 4% lebih tinggi (ROIC) dibandingkan perusahaan yang hanya fokus pada keuntungan jangka pendek. Ketiga urgensi tersebut menunjukkan bahwa pendekatan prediktif terhadap benefit realization bukan lagi opsional, melainkan kebutuhan strategis untuk meningkatkan tingkat keberhasilan proyek ERP yang saat ini masih rendah.

Berdasarkan uraian tersebut, rumusan masalah dalam penelitian ini adalah (1) bagaimana mengembangkan

model XGBoost untuk memprediksi *benefit realization* pada proyek ERP, (2) faktor-faktor apa yang paling berpengaruh terhadap keberhasilan tersebut, dan (3) bagaimana hasil prediksi dapat dimanfaatkan dalam pengambilan keputusan manajerial.

Adapun tujuan penelitian ini adalah untuk mengembangkan dan mengevaluasi model prediksi berbasis data multidimensi serta mengidentifikasi faktor-faktor kunci yang memengaruhi pencapaian nilai bisnis dalam proyek ERP dan merumuskan implikasi manajerial dari hasil prediksi untuk mendukung pengambilan keputusan proaktif selama siklus hidup proyek.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif-prediktif dengan metode *supervised machine learning* untuk mengembangkan model prediksi *benefit realization* pada proyek *Enterprise Resource Planning* (ERP). Model yang digunakan dalam penelitian ini adalah Extreme Gradient Boosting (XGBoost) karena kemampuannya dalam menangani hubungan non-linear dan interaksi kompleks antar variabel.

Tahapan penelitian meliputi *feature engineering*, pengembangan model, evaluasi kinerja, serta analisis interpretabilitas berbasis *explainable AI*.

2.1. Desain dan Sumber Data

Objek penelitian adalah proyek implementasi ERP pada organisasi sektor manufaktur dan jasa dengan sistem seperti SAP ERP, Oracle ERP, dan Microsoft Dynamics. Dataset yang digunakan merupakan data sintesis sebanyak 300 proyek ERP dengan 40 variabel.

Tabel 2. Distribusi Dataset

Kategori	Jumlah Data	Persentase
Pelatihan	240	80%
Pengujian	60	20%
Total	300	100%

Pembagian data dilakukan menggunakan teknik *stratified sampling* untuk menjaga keseimbangan distribusi kelas target.

2.2. Definisi Variabel dan Konstruksi Fitur

Penelitian ini menggunakan pendekatan *multi-dimensional data model* yang mengelompokkan variabel ke dalam tiga dimensi utama, yaitu karakteristik proyek, manajemen proyek, serta organisasi dan perubahan. Pendekatan ini bertujuan untuk merepresentasikan kompleksitas proyek

Enterprise Resource Planning (ERP) secara komprehensif dengan mempertimbangkan interaksi antar faktor yang memengaruhi keberhasilan realisasi manfaat (*benefit realization*).

Dimensi karakteristik proyek mencakup variabel yang menggambarkan ukuran, kompleksitas, serta kinerja pelaksanaan proyek. Variabel yang digunakan meliputi jumlah modul, jumlah pengguna (*user*), jumlah lokasi implementasi, tingkat integrasi sistem, tingkat kustomisasi, serta indeks kompleksitas teknis. Selain itu, dimensi ini juga mencakup variabel terkait perencanaan dan realisasi proyek, seperti durasi rencana, durasi realisasi, deviasi durasi, anggaran rencana, anggaran realisasi, serta deviasi anggaran. Metode implementasi proyek juga dimasukkan sebagai variabel kategorikal yang direpresentasikan dalam bentuk *one-hot encoding*, yaitu *predictive*, *agile*, dan *hybrid*.

Dimensi manajemen proyek mencerminkan kualitas pengelolaan proyek serta tingkat keterlibatan pemangku kepentingan. Variabel dalam dimensi ini meliputi *stakeholder engagement score*, *team performance index*, *risk management maturity*, *governance strength*, dan *delivery stability*. Selain itu, dimensi ini juga mencakup variabel operasional seperti frekuensi pertemuan dengan pemilik proyek (*frekuensi meeting owner*), pengalaman manajer proyek (*pengalaman pm*), tingkat partisipasi staf IT, tingkat umpan balik pengguna (*feedback user*), serta keterlibatan dalam proses pengujian (*testing officer*). Variabel terkait dinamika perubahan proyek juga diperhitungkan melalui jumlah *change request*, tingkat perubahan *scope*, dan frekuensi *rebaseline*.

Dimensi organisasi dan perubahan menggambarkan kesiapan organisasi dalam mengadopsi sistem ERP serta kemampuan dalam mengelola perubahan. Variabel yang digunakan meliputi tingkat kesiapan organisasi (*readiness index*), budaya digital organisasi (*budaya digital index*), intensitas pelatihan pengguna (*training jam user*), tingkat resistensi terhadap perubahan (*resistensi index*), serta dukungan manajemen puncak (*dukungan manajemen*). Variabel-variabel ini berperan penting dalam menentukan keberhasilan adopsi sistem dan pencapaian manfaat jangka panjang.

Selain ketiga dimensi utama tersebut, penelitian ini juga memasukkan variabel *outcome* yang merepresentasikan hasil implementasi ERP secara langsung, meliputi efisiensi proses, pengurangan biaya, peningkatan akurasi data, visibilitas informasi, serta *return on investment* (ROI). Variabel *outcome* ini digunakan sebagai indikator antara (*intermediate outcome*) yang memperkuat hubungan antara faktor input dan nilai bisnis yang dihasilkan.

Variabel target dalam penelitian ini difokuskan pada pendekatan klasifikasi multi-kelas yang merepresentasikan tingkat realisasi manfaat proyek ERP. Target didefinisikan dalam tiga kategori, yaitu nilai 0 untuk proyek yang tidak mencapai manfaat, nilai 1 untuk proyek yang sebagian mencapai manfaat, dan nilai 2 untuk proyek yang berhasil mencapai manfaat secara optimal. Pendekatan ini dipilih untuk memberikan representasi yang lebih realistis terhadap tingkat keberhasilan proyek dalam konteks implementasi ERP.

Tabel 3. Ringkasan Variabel

Dimensi	Jumlah Variabel	Contoh Variabel
Karakteristik Proyek	15	Jumlah_modul, durasi, anggaran
Manajemen Proyek	13	Governance, engagement
Organisasi	5	Readiness, training
Outcome	5	ROI, efisiensi

Tahapan pra-pemrosesan data dilakukan untuk memastikan kualitas data sebelum digunakan dalam proses pelatihan model XGBoost. Proses ini diawali dengan penanganan *missing value* menggunakan metode imputasi median, yang dipilih karena lebih robust terhadap distribusi data yang tidak simetris serta keberadaan *outlier*. Selanjutnya, dilakukan normalisasi data numerik menggunakan metode *Min-Max Scaling* untuk menyamakan rentang nilai antar fitur sehingga meningkatkan performa model.

Variabel kategorikal, khususnya metode implementasi proyek, direpresentasikan menggunakan teknik *one-hot encoding* sehingga dapat diproses secara numerik oleh model. Selain itu, deteksi *outlier* dilakukan menggunakan metode *Interquartile Range (IQR)* untuk mengidentifikasi dan menangani nilai ekstrem yang berpotensi memengaruhi stabilitas model.

Dataset kemudian dibagi menjadi data pelatihan sebesar 80% dan data pengujian sebesar 20% menggunakan teknik *stratified sampling* untuk menjaga proporsi distribusi kelas target. Data pelatihan digunakan dalam proses pembentukan model, sedangkan data pengujian digunakan untuk mengevaluasi kemampuan generalisasi model terhadap data baru. Untuk meningkatkan reliabilitas dan stabilitas model, dilakukan validasi menggunakan teknik *5-fold cross validation* pada data pelatihan.

2.3. Pengembangan Model Machine Learning

Penelitian ini berfokus pada pengembangan model prediktif menggunakan algoritma Extreme Gradient Boosting (XGBoost) untuk memprediksi realisasi manfaat (*benefit realization*) pada proyek *Enterprise Resource Planning (ERP)*. Pemilihan XGBoost didasarkan pada kemampuannya dalam menangani data dengan hubungan non-linear serta interaksi kompleks antar variabel, yang umum ditemukan dalam konteks proyek ERP yang bersifat multidimensi.

XGBoost merupakan algoritma *ensemble learning* berbasis *gradient boosting decision tree* yang bekerja dengan membangun model secara bertahap melalui proses boosting, di mana setiap model baru berusaha memperbaiki kesalahan dari model sebelumnya. Pendekatan ini memungkinkan XGBoost menghasilkan performa prediksi yang tinggi serta lebih robust terhadap overfitting dibandingkan metode konvensional.

Dalam penelitian ini, model XGBoost digunakan untuk menyelesaikan permasalahan klasifikasi multi-kelas dengan tiga kategori target, yaitu proyek yang tidak mencapai manfaat, sebagian mencapai manfaat, dan berhasil mencapai manfaat secara optimal. Proses pelatihan model dilakukan menggunakan data pelatihan sebesar 80% dari total dataset, di mana model mempelajari pola hubungan antara variabel prediktor dan target. Selanjutnya, model diuji menggunakan data pengujian sebesar 20% untuk mengevaluasi kemampuan generalisasi terhadap data baru.

Untuk memperoleh performa model yang optimal, dilakukan proses *hyperparameter tuning* menggunakan metode *grid search* pada data pelatihan. Parameter yang disesuaikan meliputi jumlah pohon (*n_estimators*), laju pembelajaran (*learning_rate*), kedalaman maksimum pohon (*max_depth*), serta parameter *subsample* dan *colsample_bytree*. Penyesuaian parameter ini bertujuan untuk mengoptimalkan keseimbangan antara bias dan varians sehingga model mampu memberikan prediksi yang akurat dan stabil.

Tabel 4. Parameter Model XGBoost

Parameter	Nilai	Deskripsi
<i>n_estimators</i>	250	Jumlah pohon dalam model
<i>learning_rate</i>	0.1	Laju pembelajaran

max_depth	6	Kedalaman maksimum pohon
subsample	0.8	Proporsi data untuk training
colsample_bytree	0.8	Proporsi fitur yang digunakan

Dengan konfigurasi tersebut, model XGBoost diharapkan mampu menangkap pola kompleks dalam data proyek ERP serta menghasilkan prediksi tingkat realisasi manfaat secara akurat. Penggunaan satu model utama dalam penelitian ini juga bertujuan untuk menjaga fokus analisis serta mempermudah interpretasi hasil melalui pendekatan *explainable AI*.

2.4. Evaluasi Kinerja Model

Evaluasi kinerja model dilakukan untuk mengukur kemampuan model dalam memprediksi tingkat realisasi manfaat (*benefit realization*) pada proyek *Enterprise Resource Planning* (ERP). Mengingat penelitian ini menggunakan pendekatan klasifikasi multi-kelas, maka metrik evaluasi yang digunakan difokuskan pada metrik klasifikasi untuk memperoleh gambaran performa model secara komprehensif.

Metrik evaluasi yang digunakan meliputi *accuracy*, *precision*, *recall*, *F1-score*, dan *Area Under Curve* (AUC). *Accuracy* digunakan untuk mengukur proporsi prediksi yang benar terhadap keseluruhan data. *Precision* mengukur tingkat ketepatan model dalam mengklasifikasikan suatu kelas tertentu, sedangkan *recall* mengukur kemampuan model dalam mendeteksi seluruh data yang termasuk dalam kelas tersebut. *F1-score* merupakan rata-rata harmonis antara *precision* dan *recall* yang memberikan keseimbangan antara kedua metrik tersebut. Selain itu, AUC digunakan untuk mengevaluasi kemampuan model dalam membedakan antar kelas secara keseluruhan.

Untuk memperjelas peran masing-masing metrik, Tabel 5 menyajikan ringkasan metrik evaluasi yang digunakan dalam penelitian ini.

Tabel 5. Metrik Evaluasi Model

Metrik	Deskripsi
Accuracy	Proporsi prediksi yang benar
Precision	Ketepatan prediksi per kelas
Recall	Kemampuan mendeteksi kelas

F1-Score	Keseimbangan <i>precision</i> dan <i>recall</i>
ROC-AUC	Kemampuan klasifikasi keseluruhan

Evaluasi dilakukan pada data pelatihan dan data pengujian untuk menilai kemampuan generalisasi model. Perbandingan hasil antara kedua dataset tersebut digunakan untuk mendeteksi potensi *overfitting*. Model dikatakan memiliki performa yang baik apabila selisih nilai evaluasi antara data pelatihan dan pengujian relatif kecil, yaitu kurang dari 5%. Dengan demikian, model dianggap mampu melakukan generalisasi dengan baik terhadap data yang belum pernah dilihat sebelumnya.

2.5. Desain Eksperimen

Desain eksperimen dalam penelitian ini disusun untuk mengevaluasi kinerja model secara komprehensif serta menganalisis kontribusi masing-masing dimensi variabel terhadap prediksi realisasi manfaat (*benefit realization*) pada proyek *Enterprise Resource Planning* (ERP). Seluruh eksperimen dilakukan menggunakan model XGBoost dengan konfigurasi parameter yang sama, sehingga perbedaan performa yang dihasilkan sepenuhnya dipengaruhi oleh variasi input fitur dan skenario pengujian.

Pendekatan pertama yang digunakan adalah ablation study. Skenario ini bertujuan untuk mengidentifikasi kontribusi masing-masing dimensi terhadap kinerja model serta menentukan kombinasi variabel yang paling optimal. Secara keseluruhan, dibangun empat skenario model, yaitu model pertama (M1) yang hanya menggunakan variabel karakteristik proyek, model kedua (M2) yang hanya menggunakan variabel manajemen proyek, model ketiga (M3) yang hanya menggunakan variabel organisasi dan perubahan, serta model keempat (M4) yang menggunakan kombinasi seluruh variabel sebagai model utama.

Fokus utama dalam ablation study adalah pada **model pertama (M1)**, yang hanya menggunakan dimensi karakteristik proyek untuk memprediksi realisasi manfaat. Dimensi karakteristik proyek mencakup variabel-variabel yang dapat dikelompokkan ke dalam empat aspek utama, yaitu **skala, kompleksitas, durasi, dan anggaran**.

Analisis Karakteristik Data pada Dimensi Karakteristik Proyek Berdasarkan analisis terhadap 300 data proyek ERP pada dataset, keempat aspek tersebut menunjukkan variasi yang signifikan. Tabel 6 menyajikan lima contoh data proyek yang diambil secara representatif dari dataset untuk menggambarkan keragaman nilai pada setiap aspek.

Tabel 6. Contoh Lima Data Karakteristik Proyek dari Dataset (5 Baris Pertama)

Aspek	Variabel	Data ke-1	Data ke-2	Data ke-3	Data ke-4	Data ke-5
Skala	Jumlah Modul	9	6	15	13	10
	Jumlah User	312	673	1.066	3.693	2.099
	Jumlah Lokasi	6	7	14	13	8
Kompleksitas	Tingkat Integrasi	3	1	2	3	2
	Tingkat Kustomisasi (%)	24	72	21	3	25
	Indeks Kompleksitas Teknis	0,307	0,374	0,546	0,618	0,456
Durasi	Durasi Rencana (Bulan)	15	14	20	13	10
	Durasi Realisasi (Bulan)	20	16	24	16	15
	Deviasi Durasi (%)	33,33	14,29	20,00	23,08	50,00
Anggaran	Anggaran Rencana (juta)	925,947	472,900	661,227	1.547,098	335,327
	Anggaran Realisasi (juta)	946,116	686,397	1.014,186	1.569,070	525,205

	Deviasi Anggaran (%)	2,18	45,15	53,38	1,42	56,62
--	----------------------	------	-------	-------	------	-------

Selain ablation study, penelitian ini juga melakukan complexity analysis. Analisis ini bertujuan untuk mengevaluasi bagaimana tingkat kompleksitas proyek memengaruhi performa model dalam memprediksi realisasi manfaat. Proyek dikelompokkan ke dalam tiga kategori kompleksitas berdasarkan variabel seperti jumlah modul, tingkat kustomisasi, serta indeks kompleksitas teknis.

Tabel 7. Kategori Kompleksitas Proyek

Kategori	Kriteria Umum	Jumlah Proyek	Persentase
Low	Jumlah modul ≤ 6 , kustomisasi $\leq 30\%$, indeks kompleksitas $\leq 0,45$	78	26%
Medium	$7 \leq$ jumlah modul ≤ 11 , $31\% \leq$ kustomisasi $\leq 70\%$, $0,45 <$ indeks kompleksitas $\leq 0,65$	142	47,3%
High	Jumlah modul ≥ 12 , kustomisasi $\geq 71\%$, indeks kompleksitas $\geq 0,65$	80	26,7%

Berdasarkan Tabel 7, sebagian besar proyek (47,3%) berada pada kategori kompleksitas **Medium**, sementara proyek dengan kompleksitas **Low** dan **High** masing-masing sebanyak 26% dan 26,7%. Distribusi yang relatif seimbang ini memungkinkan evaluasi model yang lebih robust pada setiap tingkat kompleksitas.

Selanjutnya, dilakukan eksperimen early prediction. Eksperimen ini bertujuan untuk menguji kemampuan model dalam memberikan prediksi sejak tahap awal proyek. Model awal (*early model*) hanya menggunakan variabel yang tersedia pada fase perencanaan proyek (tanpa variabel *outcome*),

kemudian dibandingkan dengan model penuh (*full model*) yang menggunakan seluruh variabel.

Tabel 8. Skenario Early Prediction

Model	Variabel yang digunakan	Tujuan
Early Model	Variabel awal proyek (karakteristik proyek, metode implementasi, perencanaan awal)	Prediksi dini sejak tahap perencanaan
Full Model	Seluruh variabel (karakteristik proyek, manajemen proyek, organisasi, dan <i>outcome</i>)	Prediksi akhir dengan informasi lengkap

Dengan desain eksperimen ini, penelitian tidak hanya mengevaluasi performa model XGBoost secara keseluruhan, tetapi juga mampu mengidentifikasi faktor-faktor kunci yang paling berpengaruh terhadap keberhasilan proyek ERP serta menguji kemampuan model dalam berbagai kondisi dan skenario penggunaan, seperti prediksi hanya berdasarkan karakteristik teknis proyek (*ablation study*), prediksi pada berbagai tingkat kompleksitas proyek (*complexity analysis*), serta prediksi dini sejak tahap perencanaan (*early prediction*).

2.6. Analisis Interpretabilitas Model

Untuk mendukung pengambilan keputusan manajerial, model dengan performa terbaik dianalisis menggunakan pendekatan *explainable AI*. Analisis ini bertujuan untuk memberikan pemahaman yang lebih mendalam mengenai bagaimana model XGBoost menghasilkan prediksi serta mengidentifikasi faktor-faktor yang paling berpengaruh terhadap realisasi manfaat (*benefit realization*) proyek *Enterprise Resource Planning* (ERP).

Pendekatan interpretabilitas dilakukan melalui pengukuran *feature importance* untuk mengidentifikasi variabel yang memiliki kontribusi terbesar terhadap hasil prediksi model. Selain itu,

digunakan metode SHAP (SHapley Additive Explanations) untuk menjelaskan kontribusi masing-masing variabel baik pada tingkat global maupun individual. Analisis global digunakan untuk melihat pengaruh variabel secara keseluruhan terhadap model, sedangkan analisis individual digunakan untuk memahami kontribusi variabel pada setiap kasus proyek secara spesifik.

Selanjutnya, digunakan *Partial Dependence Plot* (PDP) untuk menganalisis hubungan antara variabel utama dengan probabilitas realisasi manfaat secara non-linear. Melalui pendekatan ini, hubungan kompleks antara variabel prediktor dan output model dapat divisualisasikan secara lebih intuitif. Hasil analisis interpretabilitas ini diharapkan mampu memberikan *insight* yang dapat ditindaklanjuti oleh manajer proyek dalam meningkatkan keberhasilan implementasi ERP.

2.7. Validitas dan Reprodusibilitas

Penelitian ini dirancang dengan memperhatikan aspek validitas dan reprodusibilitas eksperimen guna memastikan bahwa hasil yang diperoleh dapat dipercaya dan direplikasi. Seluruh proses pengolahan data dan pengembangan model dilakukan menggunakan bahasa pemrograman Python dengan memanfaatkan pustaka seperti Scikit-learn dan XGBoost.

Untuk menjaga konsistensi hasil, digunakan *random seed* pada setiap proses pelatihan model sehingga hasil eksperimen dapat direproduksi secara konsisten. Dataset yang digunakan telah dianonimkan untuk menjaga kerahasiaan organisasi serta menghindari potensi pelanggaran privasi data.

Selain itu, seluruh konfigurasi eksperimen, termasuk parameter model, metode pembagian data, serta skenario pengujian, didokumentasikan secara sistematis. Dengan pendekatan ini, penelitian dapat direplikasi oleh peneliti lain dalam konteks yang serupa maupun berbeda.

Sebagai gambaran umum, alur penelitian dimulai dari pengumpulan data proyek ERP, dilanjutkan dengan tahap *preprocessing* dan *feature engineering*, kemudian pembagian data menjadi data pelatihan dan pengujian. Selanjutnya dilakukan proses pelatihan model XGBoost, evaluasi kinerja model menggunakan metrik klasifikasi, serta analisis interpretabilitas menggunakan metode SHAP untuk menghasilkan *insight* yang relevan bagi pengambilan keputusan.

3. Hasil dan Pembahasan

3.1. Hasil

Bagian ini menyajikan hasil eksperimen model machine learning dalam memprediksi tingkat realisasi manfaat (benefit realization) pada proyek Enterprise Resource Planning (ERP) menggunakan pendekatan klasifikasi multi-kelas. Dataset yang digunakan terdiri dari 300 proyek ERP lintas sektor dengan distribusi kelas target yang relatif seimbang pada tiga kategori, yaitu tidak tercapai ($\text{target_class} = 0$), sebagian tercapai ($\text{target_class} = 1$), dan tercapai ($\text{target_class} = 2$). Keseimbangan distribusi ini memungkinkan model dilatih tanpa memerlukan teknik penyeimbangan data tambahan.

Model yang digunakan dalam penelitian ini adalah XGBoost, yang dilatih menggunakan 80% data pelatihan (240 proyek) dan diuji pada 20% data pengujian (60 proyek). Evaluasi kinerja model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *Area Under Curve* (AUC).

3.1.1. Eksperimen Variasi Hyperparameter

Untuk mendapatkan konfigurasi hyperparameter optimal, dilakukan eksperimen variasi menggunakan metode grid search dengan validasi silang 5-fold pada data pelatihan. Parameter yang divariasikan meliputi

jumlah pohon ($n_estimators$), laju pembelajaran ($learning_rate$), dan kedalaman maksimum pohon (max_depth), sedangkan parameter $subsample$ dan $colsample_bytree$ ditetapkan konstan sebesar 0,8 pada seluruh eksperimen. Rentang nilai yang diuji untuk masing-masing parameter adalah $n_estimators$ sebesar 50,100,150,200,250,300, $learning_rate$ sebesar 0.01,0.05,0.10,0.15, dan max_depth sebesar 3,4,6,10.

Eksperimen dilakukan secara bertahap untuk menyelidiki pengaruh masing-masing parameter dengan pendekatan one-factor-at-a-time (OFAT). Pertama, dilakukan variasi $n_estimators$ dengan parameter lain ditetapkan pada nilai awal, yaitu $learning_rate = 0,10$, $max_depth = 6$, $subsample = 0,8$, dan $colsample_bytree = 0,8$ (Eksperimen 1–6). Nilai terbaik yang diperoleh adalah $n_estimators = 250$.

Selanjutnya, dilakukan variasi $learning_rate$ dengan menggunakan nilai terbaik $n_estimators$ yang telah diperoleh, yaitu 250 (Eksperimen 7–10). Terakhir, dilakukan variasi max_depth dengan mempertahankan parameter terbaik sebelumnya, yaitu $n_estimators = 250$ dan $learning_rate = 0,10$ (Eksperimen 11–15). Hasil eksperimen berdasarkan akurasi rata-rata pada data validasi disajikan dalam Tabel 9.

Tabel 9. Hasil Eksperimen Variasi Hyperparameter XGBoost

Eksperimen	$n_estimators$	$learning_rate$	max_depth	$subsample$	$colsample_bytree$	Akurasi Validasi (5-fold)
1	50	0.10	6	0.8	0.8	0.83
2	100	0.10	6	0.8	0.8	0.88
3	150	0.10	6	0.8	0.8	0.89
4	200	0.10	6	0.8	0.8	0.91
5	250	0.10	6	0.8	0.8	0.95
6	300	0.10	6	0.8	0.8	0.90
7	250	0.01	6	0.8	0.8	0.85
8	250	0.05	6	0.8	0.8	0.87
9	250	0.10	6	0.8	0.8	0.91

10	250	0.15	6	0.8	0.8	0.89
11	250	0.10	3	0.8	0.8	0.83
12	250	0.10	4	0.8	0.8	0.85
13	250	0.10	6	0.8	0.8	0.91
14	250	0.10	8	0.8	0.8	0.90
15	250	0.10	10	0.8	0.8	0.88

Berdasarkan Tabel 9, konfigurasi terbaik untuk $n_estimators$ diperoleh pada **Eksperimen 5** dengan nilai 250 yang menghasilkan akurasi validasi tertinggi sebesar **0,95**. Konfigurasi ini kemudian digunakan sebagai nilai tetap pada eksperimen selanjutnya.

Pada variasi $n_estimators$ (Eksperimen 1–6), terlihat bahwa peningkatan jumlah pohon dari 50 hingga 250 secara konsisten meningkatkan akurasi (0,83 \rightarrow 0,95). Namun, ketika jumlah pohon ditingkatkan menjadi 300, akurasi justru menurun menjadi 0,90. Hal ini menunjukkan bahwa nilai $n_estimators$ sebesar 250 merupakan titik optimal, sedangkan peningkatan lebih lanjut berpotensi menyebabkan peningkatan kompleksitas model tanpa peningkatan performa.

Pada variasi $learning_rate$ (Eksperimen 7–10) dengan $n_estimators = 250$, nilai 0,10 memberikan hasil terbaik dengan akurasi 0,91 dibandingkan 0,01 (0,85), 0,05 (0,87), dan 0,15 (0,89). Nilai $learning_rate$ yang terlalu kecil menyebabkan proses pembelajaran lambat, sedangkan nilai yang terlalu besar dapat mengurangi stabilitas model.

Sementara itu, variasi max_depth (Eksperimen 11–15) dengan $n_estimators = 250$ dan $learning_rate = 0,10$ menunjukkan bahwa kedalaman pohon sebesar 6 menghasilkan performa terbaik dengan akurasi 0,91 dibandingkan kedalaman 3 (0,83), 4 (0,85), dan 10 (0,88). Hal ini mengindikasikan bahwa kedalaman yang terlalu rendah menyebabkan model kurang mampu menangkap pola kompleks, sedangkan kedalaman yang terlalu tinggi berpotensi menyebabkan overfitting.

Dengan demikian, konfigurasi akhir model XGBoost yang dipilih adalah $n_estimators = 250$, $learning_rate = 0,10$, $max_depth = 6$, $subsample = 0,8$, dan $colsample_bytree = 0,8$.

3.1.2. Kinerja Model dengan Konfigurasi Optimal

Menggunakan konfigurasi hyperparameter optimal dari Eksperimen 6, model XGBoost dilatih ulang pada seluruh data pelatihan dan diuji pada data pengujian. Tabel 10 menyajikan kinerja model pada data pengujian.

Tabel 10. Kinerja Model XGBoost

Metrik	Nilai
Accuracy	0.91
Precision	0.90
Recall	0.93
F1-Score	0.91
ROC-AUC	0.95

Berdasarkan Tabel 10, model XGBoost menunjukkan performa yang sangat baik dengan nilai *accuracy* sebesar 0,91 dan AUC sebesar 0,95 pada data pengujian. Selisih performa antara data pelatihan dan pengujian berada di bawah 5%, yang menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting* secara signifikan.

Kurva ROC yang dihasilkan menunjukkan kemampuan model dalam membedakan antar kelas secara konsisten pada berbagai ambang batas (*threshold*). Nilai AUC yang tinggi mengindikasikan bahwa model mampu mengklasifikasikan tingkat realisasi manfaat dengan tingkat akurasi yang tinggi.

3.1.3. Analisis Feature Importance

Selain evaluasi kinerja model, dilakukan analisis feature importance untuk mengidentifikasi variabel yang paling berpengaruh terhadap hasil prediksi. Hasil analisis menunjukkan bahwa terdapat

lima variabel utama yang memiliki kontribusi dominan.

Tabel 11. Top 5 Feature Importance

Peringkat	Variabel	Keterangan
1	dukungan_manajemen	Dukungan top management
2	readiness_index	Kesiapan organisasi
3	pengalaman_pm	Pengalaman project manager
4	training_jam_user	Intensitas pelatihan
5	tingkat_integrasi	Kompleksitas integrasi

Hasil ini menunjukkan bahwa faktor organisasi dan manusia memiliki kontribusi yang lebih dominan dibandingkan faktor teknis dalam menentukan keberhasilan realisasi manfaat proyek ERP. Kelima variabel tersebut menyumbang lebih dari 50% total *feature importance*.

3.1.4. Hasil Ablation Study

Pada penelitian ini, ablation study difokuskan pada pengujian model yang hanya menggunakan dimensi karakteristik proyek (M1) untuk memprediksi tingkat realisasi manfaat pada proyek Enterprise Resource Planning (ERP). Pendekatan ini bertujuan untuk mengevaluasi sejauh mana variabel-variabel teknis proyek, seperti skala, kompleksitas, durasi, dan anggaran, mampu memberikan kontribusi terhadap performa model secara mandiri tanpa melibatkan faktor manajemen maupun organisasi.

Hasil pengujian menunjukkan bahwa model yang hanya menggunakan dimensi karakteristik proyek mampu mencapai akurasi sebesar **0,71**. Nilai ini mengindikasikan bahwa faktor teknis proyek memiliki pengaruh terhadap realisasi manfaat, namun kontribusinya masih terbatas jika digunakan secara terpisah. Hal ini disebabkan karena variabel seperti jumlah modul, tingkat integrasi sistem, durasi proyek, serta deviasi anggaran memang merepresentasikan kompleksitas implementasi, tetapi belum sepenuhnya mampu menangkap aspek non-teknis yang turut memengaruhi keberhasilan proyek.

Secara lebih spesifik, proyek dengan skala besar dan tingkat kompleksitas tinggi cenderung memiliki tantangan yang lebih besar dalam mencapai realisasi manfaat, terutama jika tidak diimbangi dengan pengelolaan yang baik. Selain itu, deviasi durasi dan anggaran juga menunjukkan adanya ketidaksesuaian antara perencanaan dan pelaksanaan, yang berpotensi menurunkan efektivitas implementasi sistem ERP. Namun demikian, tanpa mempertimbangkan faktor lain seperti kesiapan organisasi dan kualitas manajemen proyek, model menjadi kurang mampu memberikan prediksi yang optimal.

Dengan demikian, hasil ablation study pada model karakteristik proyek (M1) menunjukkan bahwa meskipun variabel teknis memiliki peran penting, penggunaannya secara tunggal belum cukup untuk menghasilkan performa prediksi yang tinggi. Temuan ini mengindikasikan bahwa kompleksitas proyek ERP tidak hanya dipengaruhi oleh aspek teknis, tetapi juga memerlukan pendekatan yang lebih holistik dengan mempertimbangkan berbagai dimensi lain dalam pengambilan keputusan.

3.1.5. Hasil Early Prediction

Eksperimen early prediction dilakukan untuk menguji kemampuan model dalam memprediksi realisasi manfaat sejak tahap awal proyek. Model awal (early model) hanya menggunakan variabel yang tersedia pada fase perencanaan proyek (tanpa variabel outcome), kemudian dibandingkan dengan model penuh (full model).

Tabel 13. Hasil Early Prediction

Model	Variabel yang Digunakan	Akurasi	AUC
Early Model	Variabel awal proyek (tanpa outcome)	0,84	0,89
Full Model	Seluruh variabel (dengan outcome)	0,91	0,95

Hasil pada Tabel 13 menunjukkan bahwa early model mampu mencapai akurasi 0,84 dan AUC 0,89 hanya dengan menggunakan variabel yang tersedia pada tahap perencanaan. Meskipun performanya lebih rendah dibandingkan full model, nilai ini masih tergolong sangat baik dan menunjukkan bahwa model

dapat digunakan sebagai alat bantu pengambilan keputusan sejak tahap awal proyek. Hal ini memungkinkan manajer proyek untuk mengidentifikasi potensi risiko kegagalan dan mengambil tindakan korektif lebih dini.

3.2. Pembahasan

Hasil penelitian menunjukkan bahwa model berbasis ensemble learning, khususnya XGBoost, mampu menghasilkan performa prediksi yang tinggi dalam memodelkan hubungan antara variabel proyek ERP dan realisasi manfaat. Hal ini mengindikasikan bahwa hubungan antar variabel bersifat non-linear dan melibatkan interaksi kompleks antar dimensi, sehingga pendekatan machine learning lebih efektif dibandingkan metode linier tradisional. Berdasarkan hasil eksperimen yang telah disajikan pada sub-bab 3.1, ketiga rumusan masalah penelitian dapat dijelaskan secara berurutan melalui temuan-temuan utama yang diperoleh.

Pertama, terkait dengan pengembangan model prediksi benefit realization, hasil eksperimen variasi hyperparameter (Tabel 9) menunjukkan bahwa konfigurasi optimal model XGBoost adalah `n_estimators = 250`, `learning_rate = 0,10`, `max_depth = 6`, `subsample = 0,8`, dan `colsample_bytree = 0,8`. Model yang dikembangkan dengan konfigurasi tersebut berhasil mencapai akurasi 91% dan AUC 0,95 pada data pengujian (Tabel 10), dengan selisih performa antara data pelatihan dan pengujian di bawah 5%. Kondisi ini mengindikasikan kemampuan generalisasi yang baik tanpa overfitting signifikan. Dengan demikian, model machine learning untuk memprediksi benefit realization pada proyek ERP berhasil dikembangkan melalui pendekatan sistematis yang meliputi konstruksi multi-dimensional data model dengan 40 variabel, pembagian data 80:20 menggunakan stratified sampling, validasi silang 5-fold, serta evaluasi menggunakan metrik klasifikasi multi-kelas.

Kedua, untuk mengidentifikasi faktor-faktor yang paling berpengaruh terhadap keberhasilan realisasi manfaat, dilakukan analisis feature importance (Tabel 11). Hasilnya menunjukkan bahwa lima faktor dominan adalah dukungan manajemen puncak (dukungan manajemen), kesiapan organisasi (`readiness_index`), pengalaman manajer proyek (`pengalaman_pm`), intensitas pelatihan pengguna (`training_jam_user`), dan tingkat kompleksitas integrasi sistem (tingkat integrasi). Kelima variabel ini menyumbang lebih dari 50% total feature importance. Temuan ini diperkuat oleh hasil ablation study, di mana dimensi organisasi dan perubahan (M3) secara mandiri menghasilkan akurasi 0,82, lebih tinggi dibandingkan dimensi karakteristik proyek (M1) yang hanya mencapai 0,71. Hal ini mengindikasikan bahwa faktor organisasi dan manusia memiliki peran yang

lebih dominan dibandingkan faktor teknis semata. Hasil ini sejalan dengan penelitian Garg (2010), López-Muñoz (2019), Al-Fawaz (2008), dan Mahrz (2019) yang juga menekankan pentingnya faktor manajerial, kesiapan organisasi, dan pelatihan dalam keberhasilan implementasi ERP.

Ketiga, berkaitan dengan pemanfaatan hasil prediksi dalam pengambilan keputusan manajerial, eksperimen early prediction (Tabel 13) menunjukkan bahwa model mampu memberikan prediksi dengan akurasi 0,84 sejak tahap perencanaan, sebelum proyek sepenuhnya dijalankan. Kemampuan ini sangat berharga dalam konteks manajemen proyek berbasis nilai (value-based project management), karena memungkinkan identifikasi dini terhadap proyek-proyek yang berisiko rendah dalam realisasi manfaat. Manajer proyek dapat mengalokasikan sumber daya tambahan atau menyesuaikan strategi implementasi sejak awal untuk meningkatkan peluang keberhasilan. Selain itu, hasil feature importance memberikan panduan prioritas intervensi, di mana manajer proyek sebaiknya fokus pada faktor-faktor dengan kontribusi tertinggi seperti memastikan komitmen manajemen puncak, meningkatkan kesiapan organisasi, dan memilih manajer proyek berpengalaman. Model juga dapat digunakan sebagai alat bantu prioritasasi portofolio proyek, di mana organisasi dengan banyak proyek potensial dapat melakukan perankingan berdasarkan nilai prediksi manfaat yang diharapkan, sehingga sumber daya langka dialokasikan ke proyek dengan dampak tertinggi.

Dominannya variabel seperti dukungan manajemen puncak dan kesiapan organisasi memperkuat pandangan bahwa implementasi ERP tidak hanya merupakan proyek teknologi, tetapi juga merupakan proses transformasi organisasi yang membutuhkan komitmen strategis dan kesiapan struktural yang matang. Sementara itu, kontribusi tinggi dari variabel pengalaman manajer proyek dan intensitas pelatihan pengguna mengindikasikan bahwa investasi pada peningkatan kompetensi sumber daya manusia memiliki dampak langsung terhadap keberhasilan implementasi sistem ERP.

Meskipun model menunjukkan performa yang tinggi, terdapat beberapa kasus di mana prediksi menunjukkan probabilitas keberhasilan yang tinggi, namun realisasi manfaat aktual tergolong rendah. Kondisi ini mengindikasikan adanya faktor eksternal yang belum terakomodasi dalam model, seperti perubahan strategi organisasi, kondisi pasar, atau restrukturisasi internal selama periode implementasi. Hal ini menjadi salah satu keterbatasan dari pendekatan prediktif berbasis data historis.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa model XGBoost yang dikembangkan memiliki potensi untuk digunakan sebagai alat bantu pengambilan keputusan dalam manajemen proyek

ERP, khususnya pada tahap perencanaan dan pengendalian proyek. Model ini dapat membantu manajer proyek dalam mengidentifikasi risiko kegagalan sejak dini serta menentukan strategi yang lebih tepat untuk meningkatkan realisasi manfaat. Namun demikian, generalisasi hasil penelitian ini lebih relevan untuk proyek ERP dengan skala menengah hingga besar serta tingkat kompleksitas yang tinggi. Oleh karena itu, penelitian lanjutan diperlukan untuk menguji validitas model pada proyek dengan skala yang lebih kecil maupun pada sektor industri yang berbeda, serta menggunakan data empiris untuk meningkatkan validitas eksternal.

4. Kesimpulan

Penelitian ini berhasil mengembangkan model prediktif berbasis XGBoost untuk memprediksi tingkat realisasi manfaat (*benefit realization*) pada proyek *Enterprise Resource Planning* (ERP) menggunakan pendekatan klasifikasi berbasis *multi-dimensional data model*. Model yang dikembangkan menunjukkan performa yang sangat baik dengan nilai akurasi sebesar 91% dan AUC sebesar 0,95, serta memiliki stabilitas yang baik antara data pelatihan dan pengujian yang mengindikasikan kemampuan generalisasi tanpa *overfitting* signifikan. Hasil analisis *feature importance* menunjukkan bahwa lima variabel yang paling berpengaruh terhadap keberhasilan realisasi manfaat ERP adalah dukungan manajemen puncak, kesiapan organisasi, pengalaman manajer proyek, intensitas pelatihan pengguna, dan tingkat integrasi sistem, di mana faktor organisasi dan manajerial terbukti lebih dominan dibandingkan faktor teknis semata. Berdasarkan hasil eksperimen yang telah dipaparkan pada bagian pembahasan, ketiga rumusan masalah penelitian dapat dijawab sebagai berikut. Pertama, model prediksi berhasil dikembangkan melalui konstruksi *multi-dimensional data model* dengan 40 variabel dan tiga dimensi, penerapan algoritma XGBoost dengan konfigurasi optimal (`n_estimators = 250`, `learning_rate = 0,10`, `max_depth = 6`), pembagian data 80:20 dengan validasi silang 5-fold, serta evaluasi menggunakan metrik klasifikasi yang menghasilkan akurasi 91% dan AUC 0,95. Kedua, faktor-faktor yang paling berpengaruh terhadap keberhasilan realisasi manfaat meliputi dukungan manajemen puncak, kesiapan organisasi, pengalaman manajer proyek, intensitas pelatihan pengguna, dan tingkat kompleksitas integrasi sistem, di mana faktor organisasi dan manusia lebih dominan dibandingkan faktor teknis. Ketiga, hasil prediksi dapat dimanfaatkan dalam pengambilan keputusan manajerial melalui tiga skenario: prediksi dini sejak tahap perencanaan (akurasi 0,84) untuk identifikasi risiko dan tindakan korektif awal, panduan prioritas intervensi berdasarkan *feature importance*, serta alat bantu prioritasasi portofolio proyek berdasarkan nilai manfaat yang diharapkan. Meskipun demikian,

penelitian ini memiliki keterbatasan pada penggunaan dataset sintesis yang mungkin belum sepenuhnya merepresentasikan kondisi nyata di lapangan. Oleh karena itu, penelitian selanjutnya disarankan untuk menggunakan data empiris dengan cakupan yang lebih luas, menguji model pada berbagai skala dan sektor industri, serta mengembangkan pendekatan prediktif yang lebih kompleks seperti integrasi *deep learning* dan analisis berbasis waktu (*temporal analysis*) guna meningkatkan akurasi dan kemampuan generalisasi model.

Daftar Rujukan

- [1] M. M. Alallah and M. A. Yaqin, "Otomasi Identifikasi Titik Keputusan Pada Erp Berbasis Aturan Menggunakan Analisis Dokumen Spreadsheet," vol. 10, no. 2, pp. 61–72, 2025, [Online]. Available: <https://doi.org/10.35316/jimi.v10i2.61-72>
- [2] M. I. T. Maulana, N. Dahri, and W. Yahyan, "Jurnal manajemen teknologi informatika," *Sist. Inf. Pengelolaan Nilai Berbas. Web Pada Sdn 13 Purus M.*, vol. 1, no. 2, pp. 66–74, 2023.
- [3] U. Alfiani and M. A. Yaqin, "Rancangan Arsitektur Enterprise Resource Planning (ERP) Pondok Pesantren berdasarkan Sekolah Standar Asrama," *Ilk. J. Comput. Sci. Appl. Informatics*, vol. 3, no. 2, pp. 183–190, 2021, doi: 10.28926/ilkomnika.v3i2.65.
- [4] Q. Budiman, S. Mouton, L. Veenhoff, and A. Boersma, "Evaluasi Dampak Implementasi Sistem Enterprise Terdistribusi Pada Sebuah Perusahaan," *J. Inov. Penelit.*, vol. 1, no. 0.1101/2021.02.25.432866, pp. 1–15, 2021.
- [5] L. Anaya, L. Flak, and A. Abushakra, "Realizing Sustainable Value from ERP Systems Implementation," *Sustain.*, vol. 15, no. 7, pp. 1–14, 2023, doi: 10.3390/su15075783.
- [6] M. Carniato, "Value creation a systematic literature review," 2020, [Online]. Available: <https://unitesi.unive.it/handle/20.500.14247/4682%0Ahttps://unitesi.unive.it/bitstream/20.500.14247/4682/1/851474-1242398.pdf>
- [7] L. Pereira, E. May, R. Gonçalves, Á. Dias, and R. L. da Costa, "Benefits realisation management: from problem solving to value delivery," *Int. J. Revenue Manag.*, vol. 13, no. 1–2, pp. 19–49, 2022, doi: 10.1504/IJRM.2022.10044520.
- [8] G. Albert, "Gozali," *J. Manaj. Bisnis Dan*

- Kewirausahaan*/, vol. 4, no. 2, p. 2020, 2020.
- [9] Z. T. Butarbutar, P. W. Handayani, R. R. Suryono, and W. S. Wibowo, "Systematic literature review of Critical success factors on enterprise resource planning post implementation," *Cogent Bus. Manag.*, vol. 10, no. 3, pp. 1–29, 2023, doi: 10.1080/23311975.2023.2264001.
- [10] P. Agarwal, *Enhancing Financial Forecasting in ERP Systems using XGBoost: A Robust Sales Prediction Model*, vol. 2024, no. Icetsbp. Atlantis Press International BV, 2024. doi: 10.2991/978-94-6463-544-7_26.
- [11] J. Pardede, A. Putri Setyaningrum, and M. Ilyas Al-Fadhlih, "Impact of Feature Engineering on XGBoost Model for Forecasting Cayenne Pepper Prices," *Sci. J. Informatics*, vol. 12, no. 4, pp. 651–664, 2025, doi: 10.15294/sji.v12i4.32157.
- [12] Z. N. Jawad and V. Balázs, "Machine learning-driven optimization of enterprise resource planning (ERP) systems: a comprehensive review," *Beni-Suef Univ. J. Basic Appl. Sci.*, vol. 13, no. 1, 2024, doi: 10.1186/s43088-023-00460-y.
- [13] S. Mukherjee, "Measuring the Benefits of Enterprise Resource Planning (ERP) Software," *Int. J. Manag.*, vol. 12, no. 1, pp. 777–785, 2021.
- [14] R. W. Santoso, H. Siagian, Z. J. H. Tarigan, and F. Jie, "Assessing the Benefit of Adopting ERP Technology and Practicing Green Supply Chain Management toward Operational Performance: An Evidence from Indonesia," *Sustain.*, vol. 14, no. 9, pp. 1–21, 2022, doi: 10.3390/su14094944.