

Pengembangan Kerangka Kerja Berbasis Artificial Neural Network untuk Identifikasi Risiko Proyek Teknologi Informasi

Pastima Simanjuntak^{*1,4}, Sunardi², Anton Yudhana³

^{1,2,3}Fakultas Teknologi Industri, Informatika, Universitas Ahmad Dahlan, Indonesia

⁴Fakultas Teknik dan Komputer, Informatika, Universitas Putera Batam, Indonesia

email: ^{*1,4}pastima@puterabatam.ac.id, ²sunardi@mti.uad.ac.id, ³eyudhana@ee.uad.ac.id

Abstrak

Manajemen risiko proyek teknologi informasi (TI) menjadi tantangan yang memerlukan pendekatan analitis yang efektif. Penelitian ini mengembangkan kerangka kerja berbasis Artificial Neural Network (ANN) untuk mengidentifikasi dan mengklasifikasi risiko pada proyek TI. Penelitian ini melibatkan beberapa tahap, mulai dari pengumpulan data historis proyek, pra-pemrosesan data, pelatihan model ANN, hingga interpretasi hasil prediksi risiko. Model ANN dirancang untuk menangani fitur-fitur statis proyek seperti ukuran tim, anggaran, durasi, dan menghasilkan klasifikasi risiko berdasarkan pola yang dikenali dalam data. Evaluasi model menunjukkan hasil yang memadai dengan akurasi 66%, presisi 48%, recall 51%, dan F1-score 50%. Analisis lebih lanjut diperlukan untuk mengatasi ketidakseimbangan kelas dan mengoptimalkan hyperparameter model agar meningkatkan kinerja prediksi. Penelitian ini memberikan kontribusi terhadap penerapan ANN dalam manajemen risiko proyek TI, dengan potensi implementasi pada berbagai organisasi yang menghadapi tantangan serupa.

Kata Kunci: Kerangka Kerja, Algoritma, ANN, Risiko Proyek TI

Abstract

Information technology (IT) project risk management is a challenge that requires an effective analytical approach. This research develops an Artificial Neural Network (ANN)-based framework to identify and classify risks in IT projects. The research involves several stages, from collecting historical project data, pre-processing the data, training the ANN model, to interpreting the risk prediction results. The ANN model is designed to handle static project features such as team size, budget, duration, and generate risk classifications based on patterns recognized in the data. Evaluation of the model showed adequate results with 66% accuracy, 48% precision, 51% recall, and 50% F1-score. Further analysis is needed to address class imbalance and optimize model hyperparameters to improve prediction performance. This research contributes to the application of ANN in IT project risk management, with the potential to be implemented in organizations facing similar challenges.

Keywords: Framework, Algorithm, ANN, IT Project Risk

1. PENDAHULUAN

Kebutuhan sistem teknologi informasi (TI) yang handal dan inovatif dalam era digital saat ini semakin meningkat di berbagai sektor industri, baik swasta maupun pemerintahan. Proyek TI menjadi elemen vital dalam mendukung transformasi digital, efisiensi operasional, dan peningkatan daya saing organisasi. Namun, proyek TI memiliki tingkat kompleksitas [1] dan ketidakpastian yang tinggi sehingga sangat rentan terhadap berbagai risiko. Berdasarkan sejumlah penelitian dan laporan industri, tingkat kegagalan proyek TI masih tergolong tinggi, terutama karena ketidakmampuan dalam mengidentifikasi dan mengelola risiko secara tepat sejak tahap awal proyek [2].

Risiko dalam proyek TI dapat bersifat teknis, organisasi, hingga eksternal [3]. Risiko teknis meliputi perubahan teknologi, integrasi sistem yang kompleks, atau masalah performa perangkat lunak [4]. Risiko organisasi mencakup kurangnya keterlibatan pemangku kepentingan, manajemen proyek yang lemah, hingga komunikasi yang tidak efektif dalam tim. Sementara itu, risiko

eksternal dapat datang dari faktor regulasi, perubahan pasar, atau kondisi ekonomi global. Kompleksitas dan saling keterkaitan antara faktor-faktor tersebut menjadikan proses identifikasi risiko sebagai salah satu aspek paling menantang dalam manajemen proyek teknologi informasi [5], [6], [7].

Seiring dengan pesatnya kemajuan dalam bidang kecerdasan buatan, pendekatan berbasis *deep learning* menawarkan potensi besar dalam mengatasi tantangan tersebut. *Machine learning* mampu melakukan analisis data dalam jumlah besar dan mengungkap pola tersembunyi yang sulit dikenali oleh metode tradisional. Salah satu algoritma yang relevan dalam konteks ini adalah *Artificial Neural Network* (ANN) [1], [25] yang sangat efektif dalam memodelkan hubungan non-linear antar variabel dalam data. Kemampuan ini menjadikan model ANN sangat potensial untuk digunakan dalam mengidentifikasi dan memprediksi risiko proyek secara lebih dinamis dan kontekstual [1] [8], [26].

Sebagai studi kasus, penelitian ini mengambil konteks di Kota Batam, yang dikenal sebagai kawasan industri dan teknologi strategis di Indonesia. Batam menjadi rumah bagi banyak perusahaan TI dan manufaktur yang menangani proyek berskala nasional maupun internasional. Salah satu perusahaan yang dijadikan fokus adalah PT XYZ Batam yang menangani berbagai proyek TI termasuk pengembangan sistem *enterprise*, IoT, dan otomasi industri. Meskipun telah memiliki sistem manajemen proyek yang cukup mapan, perusahaan ini masih menghadapi tantangan dalam mengantisipasi risiko secara proaktif, khususnya dalam proyek-proyek yang melibatkan banyak pihak dan berjalan dalam jangka waktu panjang.

Kondisi ini menjadi latar belakang penting bagi pengembangan kerangka kerja atau *framework* penerapan *machine learning* untuk identifikasi risiko proyek TI. Integrasi pendekatan ANN bertujuan untuk menghasilkan model yang tidak hanya mampu mengenali pola risiko berdasarkan data historis proyek, tetapi juga memprediksi kemungkinan risiko yang muncul di masa depan. Kerangka kerja ini diharapkan dapat membantu perusahaan dalam mengambil keputusan yang lebih berbasis data, mengurangi ketidakpastian, dan meningkatkan peluang keberhasilan proyek secara keseluruhan [8] [9] [10].

Penelitian terkait manajemen risiko proyek dan perangkat lunak menunjukkan pendekatan yang semakin mengandalkan teknologi kecerdasan buatan dan pembelajaran mesin. Penelitian [11], [12] mengembangkan model *Hybrid Financial Risk Predictor* (HFRP) yang menggabungkan *Convolutional Neural Networks* (CNN) dan *Long Short-Term Memory* (LSTM) untuk meningkatkan akurasi prediksi risiko keuangan. Sementara itu, penelitian [1] dan [13] menekankan potensi ANN dan *Gradient Boosting Machine* (GBM) dalam prediksi risiko proyek TI mencapai akurasi tinggi dan efisiensi biaya yang signifikan. Penelitian [13] menyoroti peran AI dalam mengubah strategi manajemen risiko proyek melalui pembelajaran adaptif berbasis data historis. Di sisi lain, penelitian [14] dan [15] membahas perbandingan metode statistik, AI, dan faktor manusia dalam keberhasilan manajemen proyek. Penelitian [2] mengkaji pentingnya persepsi dan klasifikasi risiko dalam proyek perangkat lunak, dengan fokus pada pendekatan *Fishbone Analysis* dan penilaian kuantitatif-kualitatif. Penelitian [16], [17], dan [9] mengintegrasikan manajemen risiko eksplisit dan keamanan siber dalam metodologi Agile melalui panduan dan kerangka kerja berbasis literatur. Beberapa studi lainnya menggunakan pendekatan *scientometric*, analisis sentimen, dan algoritma *hybrid* untuk menilai risiko dalam konteks digital dan sosial [3], [18], dan [19]. Penelitian [20], Tinjauan Manajemen Risiko dalam Pengembangan Agile [21], serta [22] menggarisbawahi pentingnya penanganan tantangan risiko sejak awal dalam proses pengembangan perangkat lunak dan proyek TI yang luwes. Penelitian [23] memberikan perspektif unik dari sisi konsumen terhadap risiko investasi, sedangkan penelitian [24] menunjukkan praktik-praktik *agile* yang berhasil diadopsi oleh perusahaan konsultan arsitektur melalui penerapan *Bayesian Inference Machine* (BIM). Penelitian-penelitian ini secara kolektif menunjukkan tren menuju digitalisasi dan otomatisasi dalam manajemen risiko proyek dan perangkat lunak.

Tabel 1 menunjukkan daftar penelitian yang berkaitan dengan risiko dalam berbagai konteks, mulai dari risiko keuangan, risiko proyek TI, hingga risiko keamanan siber dimana menunjukkan tren penelitian dalam manajemen risiko, penggunaan berbagai metode atau model yang digunakan serta pendekatan kualitatif dan kuantitatif dalam menganalisis dan memitigasi risiko di berbagai

bidang.

Tabel 1. Studi literatur

Peneliti	Tahun	Fokus	Metode/Model
Shi et al.	2025	Risiko keuangan	HFRP (CNN + LSTM)
Alatawi et al.	2023	Risiko proyek TI	ANN
Bauskar et al.	2024	Prediksi biaya proyek TI	GBM
Li et al.	2024	Manajemen risiko proyek	AI dan data historis
Dellermann et al.	2021	Perbandingan metode	Statistik, AI, Faktor manusia
Buganová & Šimíčková	2019	Risiko dalam proyek TI	Pendekatan manajemen risiko
Menezes et al.	2019	Risiko perangkat lunak	Fishbone Analysis
Masso et al.	2020	Klasifikasi risiko	Pendekatan kualitatif
Riaz et al.	2019	Risiko TI	Penilaian risiko kuantitatif
Vieira et al.	2020	Agile dan risiko	Kerangka manajemen risiko
Hauck & Vieira	2021	Agile dan risiko eksplisit	Panduan berbasis literatur
Salin & Lundgren	2022	Risiko keamanan siber	Integrasi dalam Agile
Cucus et al.	2023	Studi scientometric	Bibliometric Analysis
Shandana et al.	2023	Analisis risiko sosial	Analisis sentimen
Kaur et al.	2021	Manajemen risiko proyek	Hybrid FMEA dan AHP
Wassay	2023	Risiko proyek Agile	Pendekatan kualitas
Tim Penulis	2022	Tinjauan risiko Agile	Literature Review
Trzeciak	2021	Manajemen risiko perangkat lunak	Analisis faktor risiko
Garai-Fodor et al.	2022	Risiko investasi TI	Persepsi konsumen
Chathuranga et al.	2023	Adopsi BIM Agile	Studi kasus industri

Penelitian ini diharapkan memberikan kontribusi signifikan dapat dalam hal penerapan teknologi kecerdasan buatan pada manajemen risiko proyek TI secara teoretis maupun praktis. Kerangka kerja yang diusulkan juga dapat direplikasi dan disesuaikan untuk berbagai organisasi lainnya yang menghadapi tantangan serupa, terutama di lingkungan industri teknologi yang berkembang pesat seperti di Batam dan kawasan sekitarnya.

2. METODE PENELITIAN

Pelatihan model ANN pada penelitian ini berasal dari berbagai data proyek TI dengan 10.000 *dataset* yang diambil dari data gabungan (UCI, Kaggle dan Github). Analisis terhadap *dataset* dilakukan secara sistematis sehingga dapat mengidentifikasi risiko pada proyek TI dengan memanfaatkan algoritma ANN. Tahapan penelitian ditunjukkan pada Gambar 1 dengan penjelasan seperti berikut.

1. Pengumpulan Data

Tahap awal ini berfokus pada penghimpunan data historis proyek TI dari berbagai sumber. Data yang dikumpulkan dapat mencakup laporan proyek terdahulu, *log* aktivitas pengembangan, catatan *backlog*, dokumentasi masalah, dan catatan perubahan. Tujuan dari tahap ini adalah memperoleh data yang relevan dan representatif sebagai dasar dalam membangun model prediksi risiko.

2. Pra-pemrosesan Data

Setelah data terkumpul, tahap selanjutnya adalah pra-pemrosesan untuk memastikan kualitas dan kesesuaian data bagi model *machine learning*. Proses ini mencakup pembersihan data (seperti menghapus data duplikat, memperbaiki data yang hilang atau tidak konsisten), transformasi data menjadi format numerik (misalnya, *encoding* data kategorikal), serta normalisasi untuk menyamakan skala antar fitur. Proses ini sangat penting agar data dapat diproses secara efektif oleh model ANN.

3. Perancangan Arsitektur Model

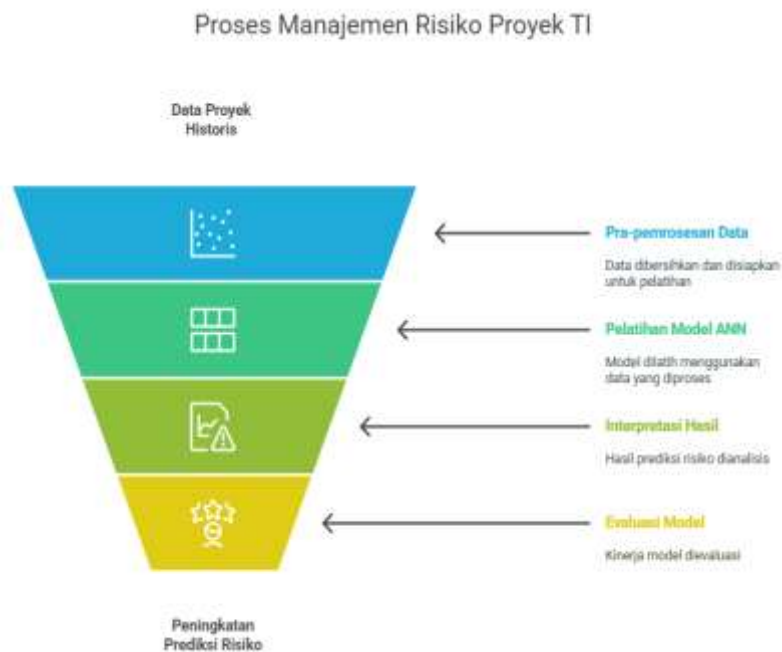
Pada tahap ini dilakukan perancangan arsitektur model ANN yang dimanfaatkan untuk melakukan klasifikasi risiko berdasarkan fitur-fitur yang telah diproses. Kombinasi kedua model ini memungkinkan sistem untuk memahami dinamika proyek sekaligus memberikan output klasifikasi risiko secara akurat.

4. Pelatihan dan Evaluasi Model

Model yang telah dirancang kemudian dilatih menggunakan data yang telah dipra-proses. Proses pelatihan dilakukan dengan membagi data menjadi data latih dan data uji untuk menghindari *overfitting*. Evaluasi kinerja model dilakukan dengan metrik evaluasi seperti akurasi, *precision*, *recall*, dan *F1-score*. Hasil evaluasi ini digunakan untuk menilai seberapa baik model mampu memprediksi risiko berdasarkan data yang tersedia.

5. Implementasi dan Interpretasi Hasil

Setelah model mencapai performa yang diharapkan, tahap akhir adalah implementasi dalam lingkungan proyek nyata. Model prediksi risiko ini dapat digunakan oleh manajer proyek dan pemangku kepentingan lainnya untuk mendeteksi potensi risiko sejak dini dan mengambil keputusan mitigasi yang tepat. Hasil prediksi juga diinterpretasikan dengan bantuan visualisasi atau teknik *explainable* untuk meningkatkan pemahaman terhadap alasan dibalik klasifikasi risiko yang diberikan model.

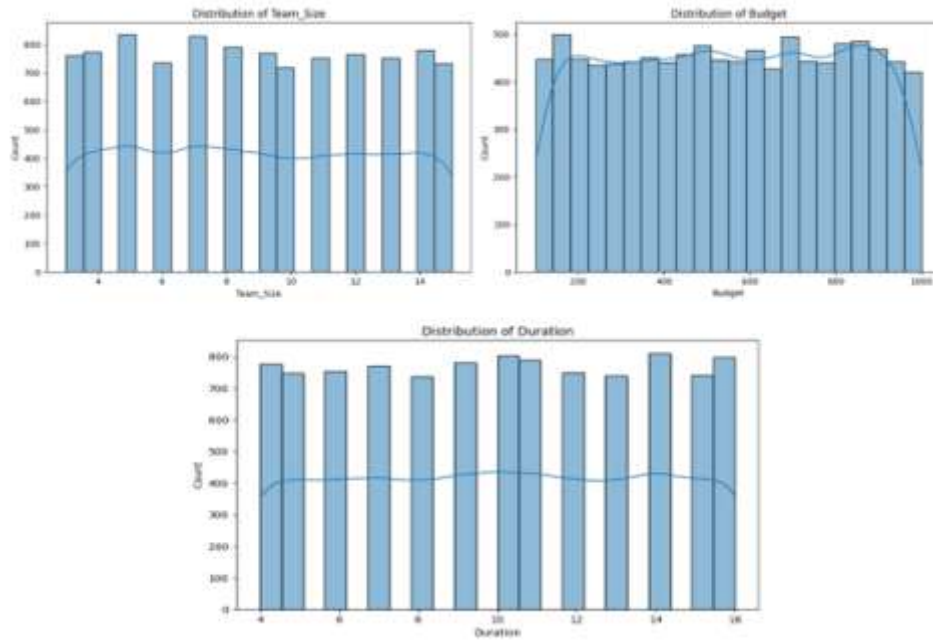


Gambar 1. Tahapan Penelitian

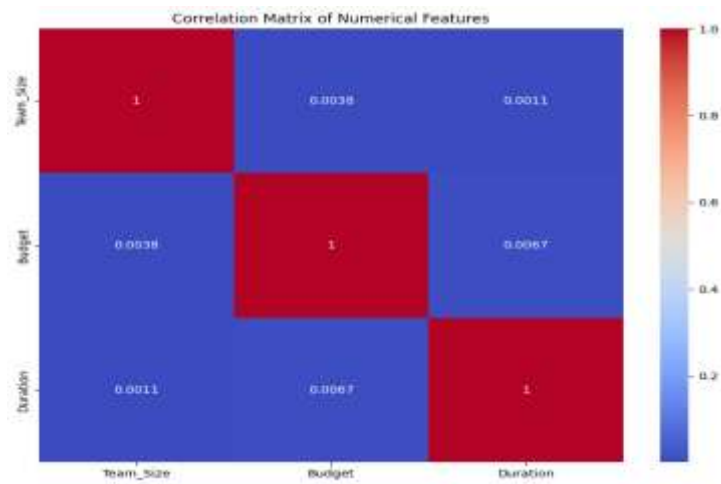
Gambar 1 merupakan langkah-langkah dalam penerapan algoritma ANN untuk identifikasi risiko proyek TI. Proses dimulai dengan pengumpulan data, yaitu mengumpulkan data historis proyek seperti laporan, *log*, dan *backlog*. Selanjutnya, dilakukan pra-pemrosesan data, yang mencakup pembersihan data, transformasi numerik, dan normalisasi agar data siap digunakan. Setelah itu, tahap arsitektur model dilakukan, di mana desain model ANN untuk klasifikasi risiko. Kemudian, dilakukan pelatihan dan evaluasi model menggunakan data yang telah diproses, dengan evaluasi berbasis metrik seperti akurasi, *precision*, dan *recall*. Akhirnya, pada tahap implementasi dan interpretasi, hasil prediksi model digunakan untuk mendukung pengambilan keputusan dalam mitigasi risiko proyek TI.

3. HASIL DAN PEMBAHASAN


Hasil eksplorasi data untuk dalam melakukan analisis resiko proyek menggunakan algoritma ANN ditunjukkan seperti Gambar 2. Gambar 3 menunjukkan bahwa fitur numerik *Team Size*, *Budget*, dan *Duration* tidak menunjukkan korelasi linier yang signifikan satu sama lain. Artinya, fitur-fitur ini tidak redundan secara statistik dan bisa saling melengkapi dalam proses pelatihan model karena masing-masing memberikan informasi yang unik.



Gambar 2. Karakteristik Distribusi Data

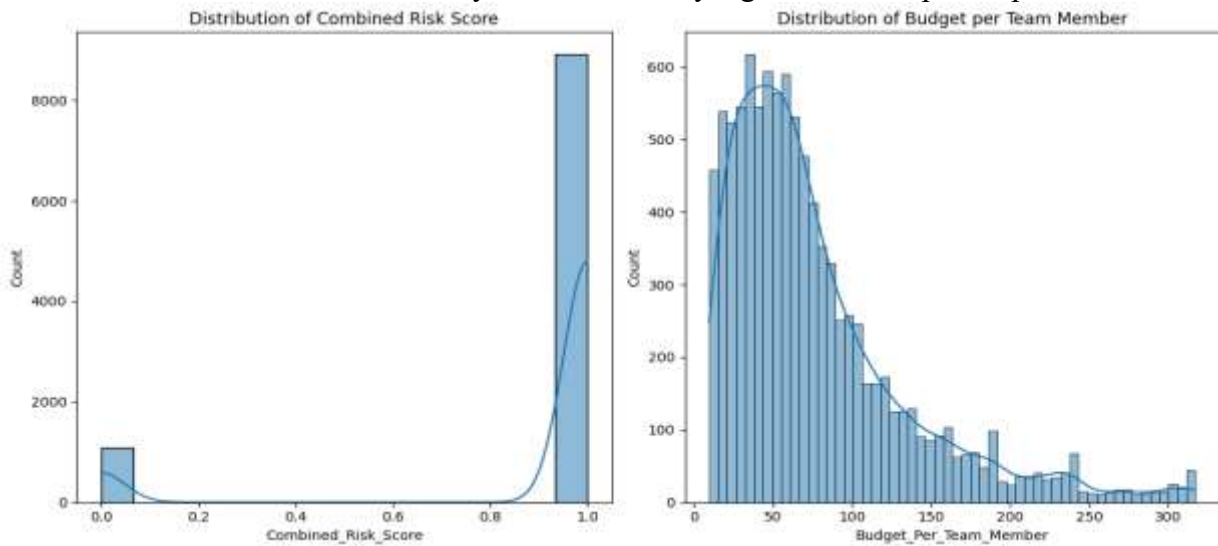


Gambar 3. Korelasi Matrik



Gambar 4. Hubungan Distribusi Data

Analisis awal terhadap fitur numerik dilakukan untuk memahami hubungan dan distribusi data sebelum pelatihan model. Berdasarkan matriks korelasi, fitur-fitur numerik seperti Team_Size, Budget, dan Duration menunjukkan korelasi linier yang sangat lemah satu sama lain, dengan nilai korelasi mendekati nol. Hal ini mengindikasikan bahwa ketiga fitur tersebut tidak saling tumpang tindih secara statistik dan masing-masing dapat memberikan kontribusi informasi yang unik dalam proses pembelajaran model. Selanjutnya, visualisasi dengan *boxplot* digunakan untuk mengevaluasi sebaran dan potensi *outlier* pada masing-masing fitur. Hasilnya menunjukkan bahwa sebaran data cukup merata dan simetris, dengan median berada di tengah rentang interkuartil (IQR). Tidak ditemukan *outlier* ekstrem pada fitur Team_Size, Budget, maupun Duration, menandakan bahwa data relatif bersih dan telah melalui proses pembersihan yang baik. Namun, Budget terlihat memiliki variasi yang paling besar dibandingkan dua fitur lainnya, yang mencerminkan adanya perbedaan skala proyek yang cukup signifikan. Temuan ini mendukung diterapkannya standarisasi data numerik menggunakan *StandardScaler* untuk menyamakan skala antar fitur dan memastikan tidak adanya fitur dominan yang mendistorsi proses pelatihan model.



Gambar 5. Distribusi Ketidakseimbangan Data

Gambar 5 menunjukkan distribusi keseimbangan data pada kedua fitur menunjukkan adanya ketidakseimbangan data dalam bentuk bimodalitas (Combined_Risk_Score) maupun *skewness* (Budget_Per_Team_Member). Hal ini perlu diperhatikan dalam proses pelatihan model karena fitur yang terlalu condong ke satu sisi dapat mengurangi efektivitas pembelajaran. Perlu dipertimbangkan normalisasi atau transformasi tambahan untuk mengatasi ketimpangan distribusi.

Table 2. Tabel korelasi

Variabel	Combined_Risk_Score	Budget_Per_Team_Member	Outcome_Gagal
Combined_Risk_Score	1	0.01727	0.00177
Budget_Per_Team_Member	0.01727	1	-0.016877
Outcome_Gagal	0.00177	-0.016877	1

Tabel 2 menunjukkan bahwa fitur Combined_Risk_Score dan Budget_Per_Team_Member memiliki hubungan yang sangat lemah terhadap variabel target Outcome_Gagal, masing-masing dengan korelasi 0,00177 dan -0,01688. Hal ini berarti secara linear, kedua fitur tersebut hampir tidak berkorelasi dengan kegagalan proyek. Namun, fitur ini tetap berpotensi berguna dalam model non-linear seperti ANN yang mampu menangkap pola kompleks di luar korelasi sederhana. Analisis ditunjukkan pada Tabel 3.

Tabel 3. Hasil Analisis

Aspek	Penjelasan
Kinerja Model	Akurasi: 0,66; Presisi: 0,48; <i>Recall</i> : 0,51; <i>F1-score</i> : 0,50; AUC-ROC: 0,75
Masalah Saat Pelatihan	<i>Error</i> karena data non-numerik; diselesaikan dengan praproses (hapus kolom, konversi tipe, tangani NaN)
Rekayasa Fitur	Combined_Risk_Score (jumlah fitur risiko), Budget_Per_Team_Member (anggaran/tim)
Korelasi Fitur Baru	Combined_Risk_Score: korelasi sangat lemah positif; Budget_Per_Team_Member: korelasi lemah negatif
Pembagian Data	Latih: 80%, Validasi: 10%, Uji: 10% (dengan <i>stratified sampling</i> berdasarkan Outcome_Gagal)
Penanganan Outlier	<i>Winsorization</i> pada Team Size, Budget, dan Duration (persentil ke-5 dan ke-95)
Pengodean Kategoris	<i>One-hot encoding</i> meningkatkan jumlah kolom
Penskalaan Fitur	StandardScaler untuk mean = 0 dan varians = 1
Langkah Berikutnya	Atasi ketidakseimbangan kelas; optimasi hiperparameter ANN dengan <i>grid/random search</i>

Model ANN yang dibangun menunjukkan performa sedang dengan akurasi sebesar 0,66, presisi 0,48, *recall* 0,51, *F1-score* 0,50, dan AUC-ROC mencapai 0,75. Selama pelatihan awal, ditemukan *error* akibat data non-numerik dalam fitur input. Masalah ini diatasi melalui proses praproses data, termasuk penghapusan kolom non-numerik, konversi tipe data menjadi numerik, dan penanganan nilai *NaN*. Dalam tahap rekayasa fitur, dua fitur baru dibuat yaitu Combined_Risk_Score dan Budget_Per_Team_Member. Fitur pertama menghimpun nilai dari beberapa fitur risiko, sementara yang kedua menghitung rasio antara anggaran dan jumlah anggota tim. Keduanya menunjukkan korelasi lemah terhadap variabel target kegagalan proyek. Data dibagi menjadi tiga bagian menggunakan stratifikasi berdasarkan label Outcome_Gagal, yaitu 80% untuk pelatihan, 10% validasi, dan 10% pengujian. Penanganan *outlier* dilakukan dengan teknik *Winsorization* pada fitur numerik utama, sementara fitur kategoris dikodekan menggunakan *one-hot encoding*. Seluruh fitur numerik juga telah distandarisasi menggunakan StandardScaler.

4. KESIMPULAN

Berdasarkan hasil analisis, model ANN menunjukkan kinerja sedang dengan akurasi 0,66 dan AUC-ROC 0,75, namun masih memiliki presisi, *recall*, dan *F1-score* yang relatif rendah. Selama pelatihan, sempat ditemukan masalah data non-numerik yang berhasil diatasi melalui praproses. Proses rekayasa fitur menghasilkan dua variabel baru Combined_Risk_Score dan Budget_Per_Team_Member yang meskipun tidak menunjukkan korelasi linear yang kuat dengan target, tetap relevan untuk model non-linear seperti ANN. Distribusi fitur menunjukkan *skewness* dan ketidakseimbangan, yang perlu diperhatikan dalam tahap *modeling*. *Boxplot* dan analisis distribusi juga mengindikasikan adanya *outlier*, meskipun sudah dilakukan *winsorization*. Lebih lanjut, penting untuk menyelidiki potensi ketidakseimbangan kelas dan melakukan *tuning hyperparameter* lebih lanjut guna meningkatkan performa model.

Sebagai langkah lanjutan, disarankan untuk menganalisis potensi ketidakseimbangan kelas dalam data target, dan mempertimbangkan pendekatan seperti *oversampling*, *undersampling*, atau pembelajaran sensitif terhadap biaya. Selain itu, penyetulan *hyperparameter* model ANN seperti jumlah lapisan, neuron, dan rasio pembelajaran diharapkan dapat meningkatkan kinerja model secara keseluruhan.

DAFTAR PUSTAKA

- [1] Alatawi, M. N., Alyahyan, S., Hussain, S., Alshammari, A., Aldaej, A. A., Alali, I. K., & Alwageed, H. (2023). A Data-Driven Artificial Neural Network Approach to Software Project Risk Assessment. *IET Software*. <https://doi.org/10.1049/2023/4324783>

- [2] Riaz, M. T., Jahan, M. S., Arif, K. S., & Butt, W. H. (2019). Risk Assessment on Software Development using Fishbone Analysis. *International Conference on Data and Software Engineering*. <https://doi.org/10.1109/ICODSE48700.2019.9092727>
- [3] Cucus, A., Sari, W. P., Aminuddin, A., Saputra, D. I. S., Hammood, W. A., & Aziza, R. F. A. (2023). *Systematic Review of IT Risk Management Using a Scientometric Approach*. 126–131. <https://doi.org/10.1109/icoiact59844.2023.10455938>
- [4] Menezes, J., Gusmão, C., & Perrelli de Moura, H. (2019). Risk factors in software development projects: a systematic literature review. *Software Quality Journal*, 27(3), 1149–1174. <https://doi.org/10.1007/S11219-018-9427-5>
- [5] Nabeel, M. Z. (2024). AI-Enhanced Project Management Systems for Optimizing Resource Allocation and Risk Mitigation. *Asian Journal of Multidisciplinary Research & Review*, 5(5), 53–91. <https://doi.org/10.55662/ajmrr.2024.5502>
- [6] Masso, J., Masso, J., Pino, F. J., Pardo, C., García, F., & Piattini, M. (2020). Risk management in the software life cycle: A systematic literature review. *Computer Standards & Interfaces*, 71, 103431. <https://doi.org/10.1016/J.CSI.2020.103431>
- [7] Buganová, K., & Šimíčková, J. (2019). Risk management in traditional and agile project management. *Transportation Research Procedia*, 40, 986–993. <https://doi.org/10.1016/J.TRPRO.2019.07.138>
- [8] Bhattacharya, N., & Kumar, P. (2025). A Comparative Analysis of Artificial Neural Network and Convolutional Neural Network Models. *Advances in Psychology, Mental Health, and Behavioral Studies (APMHBS) Book Series*, 163–188. <https://doi.org/10.4018/979-8-3693-7545-7.ch007>
- [9] Salin, H., & Lundgren, M. (2022). Towards Agile Cybersecurity Risk Management for Autonomous Software Engineering Teams. *Journal of Cybersecurity and Privacy*, 2(2), 276–291. <https://doi.org/10.3390/jcp2020015>
- [10] Trzeciak, M. (2021). *Sustainable Risk Management in IT Enterprises*. 9(7), 135. <https://doi.org/10.3390/RISKS9070135>
- [11] Shi, X., Zhang, Y., Yu, M., & Zhang, L. (2025). Deep learning for enhanced risk management: a novel approach to analyzing financial reports. *PeerJ*, 11, e2661. <https://doi.org/10.7717/peerj-cs.2661>
- [12] Huang, X. (2024). Research on Financial Time Series Risk Assessment Model Based on Computer Deep Learning. 450–453. <https://doi.org/10.1109/icmiii62623.2024.00088>
- [13] Bauskar, S. R., Madhavaram, C. R., Galla, E. P., Sunkara, J. R., Gollangi, H. K. and Rajaram, S. K. (2024) Predictive Analytics for Project Risk Management Using Machine Learning. *Journal of Data Analysis and Information Processing*, 12, 566-580. <https://doi.org/10.4236/jdaip.2024.124030>
- [14] Li, H., Yazdi, M., Nedjati, A., Moradi, R., Adumene, S., Dao, U., Moradi, A., Haghghi, A., Obeng, F., Huang, C., Kang, H.-S., Pirbalouti, R. G., Zarei, E., Dehghan, M., Darvishmotevali, M., Ghasemi, P., Fard, P. S., & Garg, H. (2024). *Harnessing AI for Project Risk Management: A Paradigm Shift* (pp. 253–272). Springer International Publishing. https://doi.org/10.1007/978-3-031-51719-8_16
- [15] Dellermann, D., Ebel, P., Soellner, M., & Leimeister, J. M. (2021). Hybrid Intelligence. *arXiv: Artificial Intelligence*. <https://doi.org/10.1007/S12599-019-00595-2>
- [16] Menezes, J., Gusmão, C., & Perrelli de Moura, H. (2019). Risk factors in software development projects: a systematic literature review. *Software Quality Journal*, 27(3), 1149–1174. <https://doi.org/10.1007/S11219-018-9427-5>
- [17] Vieira, M., Hauck, J. C. R., & Matalonga, S. (2020). *How Explicit Risk Management is Being Integrated Into Agile Methods: Results From a Systematic Literature Mapping*. <https://doi.org/10.1145/3439961.3439976>
- [18] Hauck, J. C. R., & Vieira, M. (2021). *Towards a Guide for Risk Management Integration in Agile Software Projects* (pp. 73–87). Springer, Cham. https://doi.org/10.1007/978-3-030-85521-5_6

- [19] Shandana, K. T., Aminuddin, A., Saputra, E. H., Abdulloh, F. F., Rahardi, M., & Asaddulloh, B. P. (2023). *Sentiment Analysis of Google Classroom Application Using Machine Learning Techniques*. 954–959. <https://doi.org/10.1109/icamimia60881.2023.10427706>
- [20] Kaur, H., Ul Ahsaan, S., Alankar, B., & Chang, V. (2021). A Proposed Sentiment Analysis Deep Learning Algorithm for Analyzing COVID-19 Tweets. *Information Systems Frontiers*, 23(6), 1–13. <https://doi.org/10.1007/S10796-021-10135-7>
- [21] Wassay, Md. A. (2023). Towards Challenges Faced in Agile Risk Management Practices. *International Congress on Information and Communication Technology*, 937–942. <https://doi.org/10.1109/ICICT57646.2023.10134188>
- [22] *A Review of Risk Management in Agile Development*. (2022). <https://doi.org/10.1109/icdi57181.2022.10007239>
- [23] Garai-Fodor, M., Szemere, T. P., & Csiszárík-Kocsir, Á. (2022). Investor Segments by Perceived Project Risk and Their Characteristics Based on Primary Research Results. *Risks*, 10(8), 159. <https://doi.org/10.3390/risks10080159>
- [24] Chathuranga, S. A. D., Jayasinghe, S., Antucheviciene, J., Udayanga, N., & Weerakkody, W. A. S. (2023). Practices Driving the Adoption of Agile Project Management Methodologies in the Design Stage of Building Construction Projects. *Buildings*, 13(4), 1079. <https://doi.org/10.3390/buildings13041079>
- [25] Chumakova, E. V., Korneev, D. G., Gasparian, M. S., Ponomarev, A. A., & Makhov, I. S. (2023). Building a neural network to assess the level of operational risks of a credit institution. *Journal of Theoretical and Applied Information Technology*, 101(11), 4205-4213.
- [26] Hu, Y., & Su, J. (2022). Research on credit risk evaluation of commercial banks based on artificial neural network model. *Procedia Computer Science*, 199, 1168-1176. <http://dx.doi.org/10.1016/j.procs.2022.01.148>