



Credit Card Default Analysis Using Deep Learning To Support Digital Financial Management Decision-Making

Analisis Default Kartu Kredit Dengan Deep Learning Untuk Mendukung Keputusan Manajemen Keuangan Digital

Dini Pratiwi ¹⁾; Deki Fujiansyah ²⁾

^{1,2)} Universitas Serelo Lahat

Email: ¹⁾ dinipratiwi541@gmail.com ¹⁾; dekisafawi@gmail.com ²⁾

ARTICLE HISTORY

Received [28 Januari 2026]

Revised [02 April 2026]

Accepted [07 April 2026]

KEYWORDS

Default Kartu Kredit; Deep Learning; Manajemen Keuangan Digital.

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license



ABSTRAK

Perkembangan ekonomi digital menuntut lembaga keuangan untuk mengoptimalkan manajemen risiko melalui analisis berbasis data. Penelitian ini bertujuan untuk menganalisis faktor-faktor yang memengaruhi kemungkinan default kartu kredit serta mengembangkan model prediksi menggunakan algoritma Deep Learning berbasis Artificial Neural Network (ANN) guna mendukung pengambilan keputusan manajemen keuangan digital. Data yang digunakan bersumber dari dataset publik "Default of Credit Card Clients" (UCI/Kaggle) dengan 30.000 observasi dan 23 variabel keuangan. Hasil penelitian menunjukkan bahwa model menghasilkan akurasi sebesar 81,6% dan nilai AUC sebesar 0,771, dengan spesifisitas tinggi namun recall relatif rendah. Temuan ini menunjukkan bahwa deep learning efektif dalam mengenali pola non-linear perilaku pembayaran nasabah dan dapat dijadikan alat pendukung keputusan bagi lembaga keuangan digital dalam mengidentifikasi risiko kredit serta merancang strategi mitigasi default yang lebih adaptif.

ABSTRACT

The development of the digital economy requires financial institutions to optimize risk management through data-driven analysis. This study aims to analyze the factors influencing credit card default and to develop a predictive model using a Deep Learning algorithm based on an Artificial Neural Network (ANN) to support digital financial management decision-making. The data were obtained from the public "Default of Credit Card Clients" dataset (UCI/Kaggle), consisting of 30,000 observations and 23 financial variables. The results show that the model achieved an accuracy of 81.6% and an AUC value of 0.771, with high specificity but relatively low recall. These findings indicate that deep learning is effective in capturing non-linear patterns in customer payment behavior and can serve as a decision support tool for digital financial institutions in identifying credit risk and designing more adaptive default mitigation strategies.

PENDAHULUAN

Perkembangan teknologi digital telah mengubah paradigma sistem keuangan global, termasuk dalam pengelolaan risiko kredit (Barroso & Laborda, 2022). Salah satu tantangan utama dalam sektor keuangan digital adalah meningkatnya jumlah gagal bayar (default) pada kartu kredit akibat proses penilaian kredit yang belum sepenuhnya mampu mengantisipasi perilaku nasabah secara akurat (Suryono et al., 2020). Dalam konteks manajemen keuangan digital, kemampuan mendeteksi potensi gagal bayar secara dini menjadi faktor penting bagi lembaga keuangan untuk menjaga likuiditas, menekan risiko kerugian, dan meningkatkan efisiensi pengambilan keputusan keuangan (Haoran et al., 2024).

Secara ideal (*das sollen*), lembaga keuangan diharapkan mampu melakukan penilaian kelayakan kredit dengan cepat, tepat, dan berbasis data yang komprehensif melalui penerapan teknologi analitik canggih (Supriadi et al., 2025). Namun dalam praktiknya (*das sein*), banyak institusi masih mengandalkan metode konvensional seperti regresi logistik atau penilaian manual yang bergantung pada pengalaman analis (Căvescu & Popescu, 2025). Pendekatan tersebut memiliki keterbatasan dalam mengenali pola non-linear yang kompleks pada perilaku keuangan nasabah, sehingga akurasi prediksi default kartu kredit masih rendah dan berdampak pada keputusan manajemen keuangan yang kurang optimal. Indikasi optimalisasi pada dasarnya diperlukan pada berbagai aspek (Septian, 2024).

Berbagai penelitian terdahulu telah mencoba memanfaatkan metode *machine learning* untuk meningkatkan akurasi prediksi risiko kredit. Penelitian oleh Huang (2023) menggunakan *support vector machine* dan *decision tree* untuk mengklasifikasikan risiko gagal bayar dengan hasil yang cukup baik, namun masih terbatas pada kemampuan model dalam menangani dimensi data yang besar (Huang et al., 2025). Studi berikutnya oleh Tian (2025) menerapkan *random forest* dan *gradient boosting* untuk analisis data keuangan, tetapi model tersebut memerlukan proses pra-pemrosesan yang kompleks dan belum mampu mempelajari representasi data secara mendalam (Tian et al., 2025). Dalam

perkembangannya, pendekatan *deep learning* mulai digunakan karena kemampuannya dalam mengekstraksi fitur tersembunyi dari data keuangan yang besar dan heterogen.

Kebaruan penelitian ini terletak pada penerapan algoritma *deep learning* berbasis *artificial neural network (ANN)* untuk menganalisis kemungkinan default kartu kredit dengan menggunakan dataset publik "Default of Credit Card Clients" dari UCI Machine Learning Repository. Model ini dirancang tidak hanya untuk meningkatkan akurasi klasifikasi risiko kredit, tetapi juga untuk mendukung proses *financial decision-making* dalam manajemen keuangan digital melalui pendekatan prediktif yang lebih adaptif dan berbasis data aktual. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi praktis bagi lembaga keuangan dalam mengembangkan sistem manajemen risiko kredit yang lebih cerdas dan responsif terhadap dinamika perilaku konsumen di era ekonomi digital.

LANDASAN TEORI

Manajemen Keuangan Digital

Manajemen keuangan digital merupakan proses pengelolaan keuangan yang mengintegrasikan teknologi informasi dan analisis data dalam pengambilan keputusan keuangan. Menurut Mihaela et al. (2025), digitalisasi keuangan memungkinkan lembaga keuangan melakukan efisiensi operasional, otomatisasi proses, dan pengelolaan risiko yang lebih adaptif (Mihaela et al., 2025). Dalam konteks kredit, pendekatan digital membantu manajer keuangan dalam menilai kelayakan nasabah secara real-time berdasarkan data transaksi, riwayat pembayaran, dan perilaku konsumsi.

Risiko Default Kartu Kredit

Default kartu kredit terjadi ketika pemegang kartu gagal melakukan pembayaran minimum dalam jangka waktu tertentu. Menurut Chen (2023), faktor penyebab utama default meliputi tingkat pendapatan, jumlah tagihan, histori pembayaran, serta tingkat penggunaan kredit (Chen et al., 2023). Pengelolaan risiko default yang tidak efektif dapat berdampak negatif terhadap profitabilitas lembaga keuangan dan stabilitas sistem keuangan digital. Oleh karena itu, pemodelan prediksi default yang akurat menjadi kebutuhan mendesak dalam mendukung manajemen keuangan digital yang berkelanjutan.

Penerapan Machine Learning dalam Prediksi Kredit

Metode *machine learning* telah banyak digunakan untuk mengidentifikasi risiko kredit berdasarkan pola historis (Chang et al., 2024). Dalam tulisan Chang, terdapat pengguna algoritma *support vector machine (SVM)* untuk memprediksi default kartu kredit dan menunjukkan peningkatan akurasi dibandingkan regresi logistik. Selanjutnya, Cha et al (2021) melakukan perbandingan beberapa algoritma *machine learning* seperti *random forest* dan *gradient boosting* (Cha et al., 2021), yang terbukti lebih unggul dalam mendeteksi nasabah berisiko tinggi. Namun demikian, pendekatan ini masih terbatas pada pemrosesan fitur non-linear yang kompleks.

METODE PENELITIAN

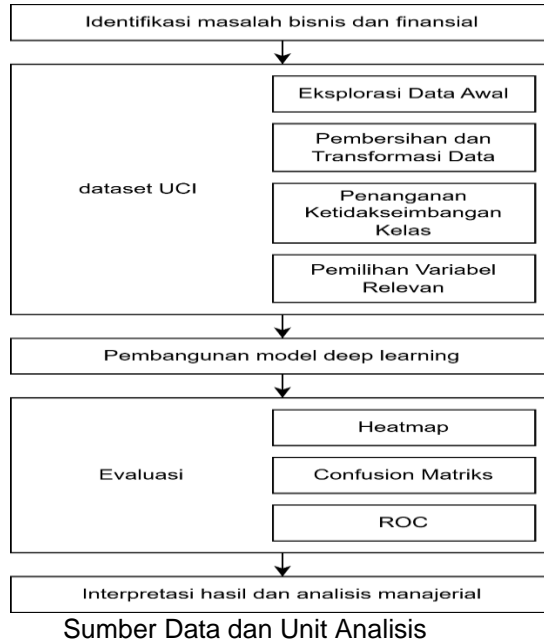
Pendekatan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif prediktif dengan metode *deep learning* untuk menganalisis faktor-faktor yang memengaruhi kemungkinan *default* kartu kredit dan implikasinya terhadap pengambilan keputusan dalam manajemen keuangan digital. Pendekatan ini dipilih karena *deep learning* mampu mengekstraksi pola non-linear dan kompleks dari data keuangan yang besar, sehingga relevan untuk mendukung sistem pengambilan keputusan berbasis data (*data-driven financial management*).

Pengolahan data dilakukan melalui beberapa tahap sistematis agar model yang dihasilkan memiliki validitas dan reliabilitas tinggi. Keseluruhan tahapan penelitian ini termasuk pengolahan data ditunjukkan pada Gambar 1. Secara konseptual, penelitian ini berada pada irisan antara bidang manajemen keuangan, analitik data, dan bisnis digital, di mana teknologi kecerdasan buatan digunakan sebagai alat bantu untuk memperkuat pengambilan keputusan strategis lembaga keuangan digital.



Gambar 1 Alur Penelitian



Penelitian ini memanfaatkan dataset publik “Default of Credit Card Clients” yang tersedia di Kaggle/UCI Machine Learning Repository. Dataset tersebut mencakup 30.000 nasabah kartu kredit di Taiwan, dengan 23 variabel yang terdiri dari karakteristik demografis (jenis kelamin, usia, pendidikan, status pernikahan), data keuangan (limit kredit, tagihan bulanan, dan jumlah pembayaran), serta status default sebagai variabel dependen. Unit analisis dalam penelitian ini adalah individu pemegang kartu kredit, dan periode data yang dianalisis mencerminkan aktivitas keuangan nasabah selama enam bulan terakhir. Data ini dinilai representatif untuk menggambarkan dinamika perilaku pembayaran dalam sistem keuangan digital di Asia Timur, yang memiliki kemiripan struktural dengan sistem keuangan digital di negara berkembang lainnya.

Populasi dan Teknik Sampling

Populasi penelitian adalah seluruh nasabah kartu kredit yang tercatat dalam dataset. Karena data telah tersedia secara lengkap, penelitian ini menggunakan teknik *census sampling*, yaitu menganalisis seluruh observasi tanpa pengambilan sampel acak tambahan. Untuk keperluan pelatihan model, dataset dibagi menjadi dua bagian menggunakan teknik stratified random sampling agar proporsi antara nasabah default dan non-default tetap seimbang:

- ❖ 80% data digunakan untuk *training set* (pembangunan dan pelatihan model)
- ❖ 20% data digunakan untuk *testing set* (evaluasi kinerja model)

Model Analisis dan Pengujian Hipotesis

Penelitian ini mengimplementasikan model Deep Neural Network (DNN) yang terdiri dari beberapa lapisan tersembunyi (*hidden layers*) untuk menangkap hubungan non-linear antar variabel keuangan.

$$\begin{aligned}
 \text{Akurasi} &= \frac{TP + TN}{TP + TN + FP + FN} \\
 \text{Presisi} &= \frac{TP}{TP + FP} \\
 \text{Recall} &= \frac{TP}{TP + FN} \\
 F1 &= 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}}
 \end{aligned}$$

Selain itu, kurva ROC (Receiver Operating Characteristic) dan area di bawahnya (AUC) digunakan untuk menilai kemampuan model dalam membedakan nasabah berisiko tinggi dan rendah. Hasil model

deep learning ini tidak hanya berfungsi sebagai prediktor teknis, tetapi juga memiliki implikasi strategis bagi manajemen keuangan digital. Model dapat digunakan sebagai dasar pengambilan keputusan untuk

- Mengidentifikasi nasabah berisiko tinggi sejak dini.
- Menetapkan kebijakan limit kredit adaptif.
- Mengoptimalkan strategi penagihan berbasis data.

Validitas model dijaga melalui:

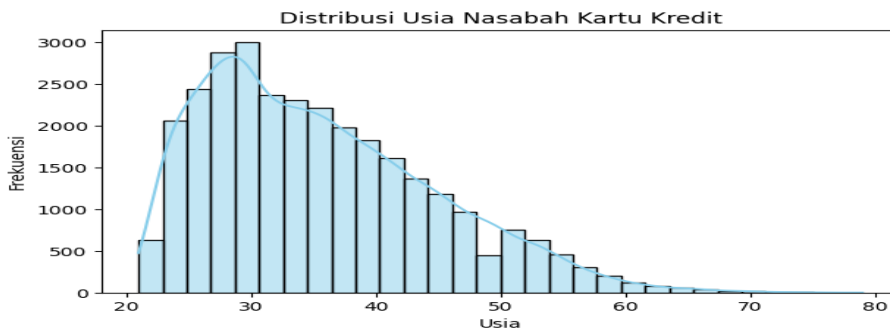
- Pemisahan data pelatihan dan pengujian secara ketat (hold-out validation).
- Penggunaan cross-validation untuk menghindari bias sampel.
- Replikasi kode dan seed acak untuk menjaga reliabilitas hasil.

HASIL DAN PEMBAHASAN

Karakteristik Data: Distribusi Usia Nasabah

Ditampilkan distribusi usia nasabah kartu kredit yang bersifat *right-skewed* dengan puncak frekuensi pada rentang usia sekitar 27–33 tahun yang ditunjukkan pada Gambar 2. Interpretasi ekonomi dari pola ini mencakup aspek segmentasi demografis seperti mayoritas nasabah berada pada kelompok usia produktif muda (25–35 tahun).

Gambar 2. Distribusi Usia Nasabah Kartu Kredit

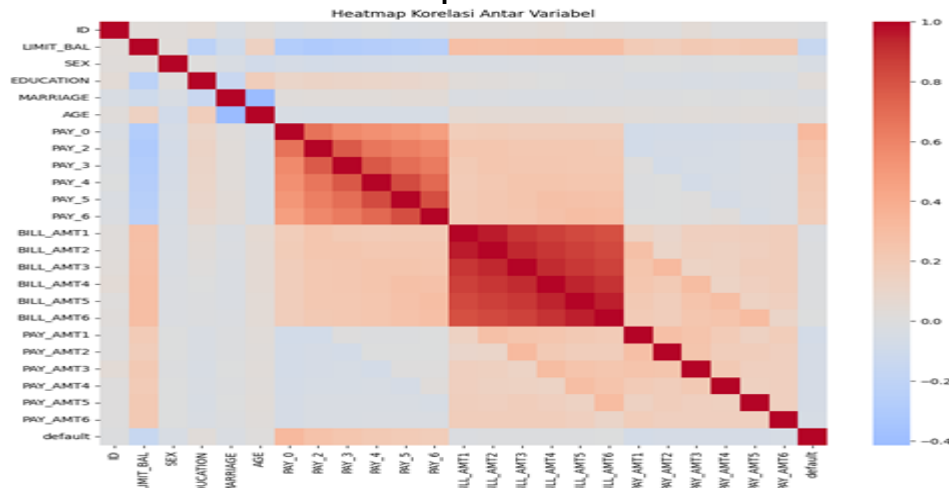


Kelompok ini cenderung memiliki mobilitas ekonomi tinggi dan profil kredit yang berbeda dibandingkan kelompok usia lanjut. Kemudian implikasi risiko dan strategi pemasaran yaitu Lembaga keuangan digital dapat merancang produk kredit yang disesuaikan (produk entry-level, limit bertahap) serta program edukasi keuangan untuk segmen muda guna mengurangi potensi default. Terakhir generalizability dataset, dominasi usia muda perlu diperhitungkan saat menerapkan model pada populasi lain yang memiliki struktur usia berbeda hasil prediksi mungkin berubah bila distribusi usia berbeda.

Analisis Korelasi Antar Variabel

Klaster korelasi yang jelas antara beberapa grup fitur atau sering disebut dengan heatmap ditunjukkan pada Gambar 3.

Gambar 3. Heatmap Korelasi Antar Variabel





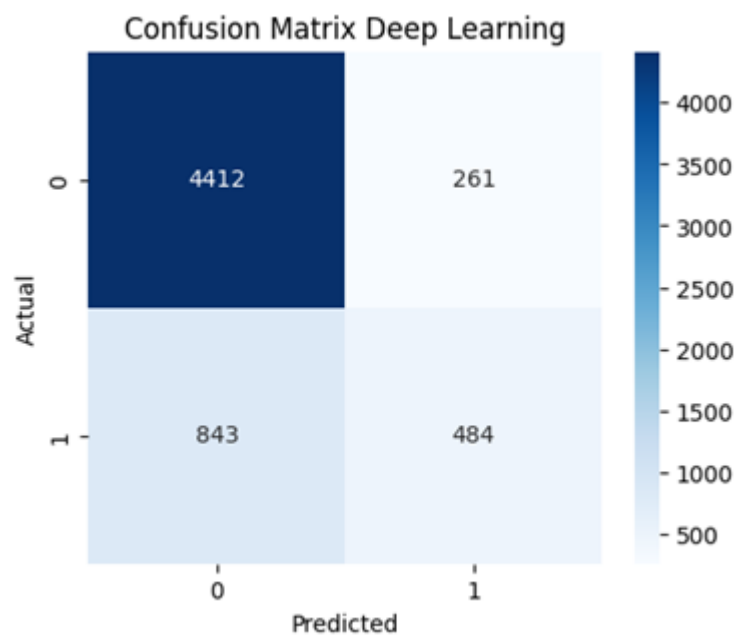
- Klaster riwayat pembayaran (PAY_0 sampai PAY_6)
Terdapat korelasi positif tinggi antar variabel PAY_, mengindikasikan bahwa perilaku pembayaran nasabah bersifat konsisten dari bulan ke bulan. Hubungan ini konsisten dengan literatur yang menyatakan bahwa riwayat keterlambatan adalah prediktor utama default.
- Klaster jumlah tagihan (BILL_AMT1–BILL_AMT6)
Variabel tagihan bulanan juga saling berkorelasi tinggi satu sama lain mencerminkan pola konsumsi/utang yang stabil pada beberapa bulan terakhir.
- LIMIT_BAL vs default
Terlihat korelasi negatif yang relatif kuat antara limit kredit (LIMIT_BAL) dan status default, yakni nasabah dengan limit lebih tinggi cenderung memiliki probabilitas default lebih rendah dalam dataset ini. Hal ini dapat dipahami sebagai proxy kemampuan kredit dan/atau seleksi penerbitan limit (nasabah berprofil lebih stabil mendapat limit lebih tinggi).
- Korelasi antar-klaster
Korelasi moderat antara PAY_ dan BILL_AMT terhadap variabel default menegaskan signifikansi fitur-fitur ini dalam model.

Dari sisi metodologis, adanya korelasi antar fitur mengingatkan perlunya menangani multikolinearitas saat interpretasi model tetapi untuk *deep learning* secara langsung hal ini bukan masalah utama karena jaringan dapat mempelajari representasi terkompresi; tetap dianjurkan memakai teknik interpretabilitas (mis. SHAP) untuk memisahkan kontribusi fitur.

Performa Model Confusion Matrix dan Metrik Klasifikasi

Confusion matrix yang ditunjukkan pada Gambar 4 memberikan nilai numerik sehingga berdasarkan angka-angka tersebut dihitung metrik kinerja.

Gambar 4. Confusion Matrix Deep Learning



$$Akurasi = \frac{TN + TP}{total} = \frac{4412 + 484}{6000} = 0,816(81,6\%)$$

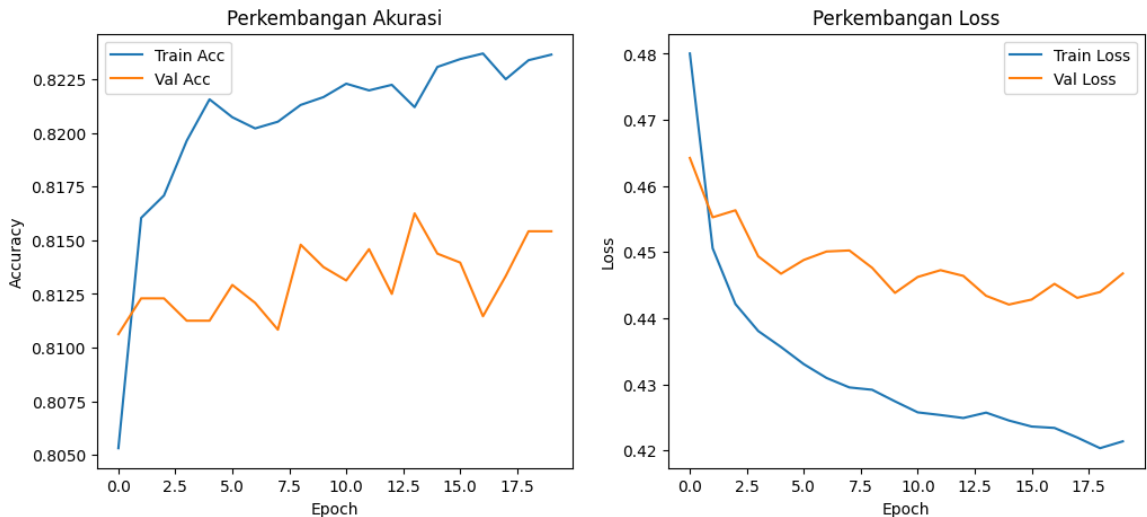
$$Presisi = \frac{TP}{TP + FP} = \frac{484}{745} \approx 0,650(65,0\%)$$

$$Recall = \frac{TP}{TP + FN} = \frac{484}{1327} \approx 0,365(36,5\%)$$

$$Specificity = \frac{TN}{TN + FP} = \frac{4412}{4673} \approx 0,944(94,4\%)$$

Model cukup handal mengidentifikasi nasabah *non-default* (spesifisitas tinggi), tetapi relatif kurang sensitif dalam mendeteksi nasabah *default* (recall rendah). Dengan kata lain, model cenderung menghasilkan lebih banyak false negatives kasus-kasus di mana nasabah yang sebenarnya akan *default* tidak teridentifikasi sebagai berisiko. Dalam konteks manajemen risiko, false negatives lebih berbahaya karena berpotensi menyebabkan kerugian tak terduga.

Gambar 5. Perkembangan Akurasi dan Loss

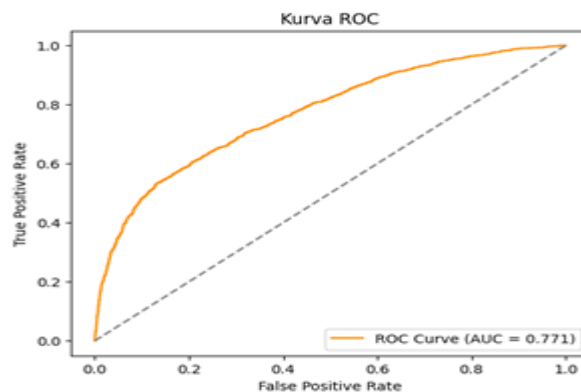


Kemudian akurasi dan loss ditunjukkan pada Gambar 5. Hal ini memperlihatkan perkembangan *train* dan *validation accuracy* serta *loss* selama epoch yakni Train accuracy meningkat sampai kisaran ~0,834; val accuracy stabil di kisaran ~0,81–0,815. Train loss menurun konsisten dan lebih rendah dari val loss, yang menunjukkan adanya celah performa antara pelatihan dan validasi. Terdapat indikasi *mild overfitting* model belajar pola pada data pelatihan lebih baik daripada validasi, namun kesenjangan tidak ekstrem. Penggunaan *dropout*, *batch normalization*, dan *early stopping* seperti dijelaskan di metode nampaknya membantu menekan overfitting. Untuk peningkatan lebih lanjut dapat dipertimbangkan regularisasi lebih kuat, pengurangan kompleksitas model, atau augmentasi fitur.

Kurva ROC dan AUC

Lalu kurva ROC yang ditunjukkan pada Gambar 6 dengan AUC ≈ 0,771. AUC pada rentang ini mengindikasikan kemampuan diskriminasi yang sedang sampai baik: model dapat membedakan kelas default dan non-default lebih baik daripada tebakan acak (AUC = 0.5), namun belum mencapai kategori excellent (AUC > 0.9).

Gambar 6. Kurva ROC



Kombinasi AUC = 0.771 dan nilai recall rendah menunjukkan adanya trade-off antara memilih ambang (threshold) yang lebih konservatif (mengutamakan spesifisitas) atau agresif (mengutamakan sensitivitas). Saat tujuan organisasi adalah meminimalkan kerugian akibat default, perlu dipertimbangkan pemindahan threshold untuk meningkatkan recall walau mengorbankan precision.



Recall Rendah dengan AUC Cukup

Fenomena utama yang muncul yakni AUC yang wajar (0,771) tetapi recall rendah ($\approx 36,5\%$). Faktor penyebab dan interpretasinya ialah

1. Ketidakeimbangan kelas
Proporsi default $\sim 22\%$ menyebabkan model cenderung “tertarik” pada kelas mayoritas (non-default). Metrik overall (accuracy) terlihat tinggi tetapi tidak mencerminkan performa pada kelas minoritas.
2. Threshold default (0.5)
Evaluasi confusion matrix kemungkinan menggunakan ambang 0.5; dengan threshold ini model mungkin lebih menjaga precision daripada recall. Menurunkan threshold dapat meningkatkan recall.
3. Biaya kesalahan (cost asymmetry)
Model saat ini tampaknya dioptimalkan untuk meminimalkan false positives (menghindari salah menandai nasabah sehat sebagai berisiko), yang sesuai jika biaya false positive tinggi (mis. hilangnya pendapatan). Namun bila prioritas adalah mencegah loss akibat default, strategi harus bergeser ke meminimalkan false negatives.
4. Representasi fitur
Meskipun *PAY_* dan *BILL_AMT* sangat informatif (lihat heatmap), mungkin ada fitur penting yang tidak tersedia (mis. data perilaku transaksi real-time, data demografi lebih rinci, data makroekonomi), sehingga kemampuan model untuk mendeteksi semua default terbatas.

Implikasi Manajerial

Berdasarkan hasil di atas, beberapa implikasi dan rekomendasi untuk manajemen keuangan digital diajukan seperti

1. Gunakan model sebagai alat bantu keputusan, bukan pengambil keputusan tunggal
Dengan spesifisitas tinggi, model baik untuk *screening negative* (menyaring nasabah yang hampir pasti aman). Namun untuk penentuan langkah intervensi terhadap kandidat berisiko, perlu ditambahkan aturan bisnis dan penilaian manusia.
2. Threshold tuning sesuai tujuan bisnis
Jika prioritas adalah mengurangi kerugian dari default, turunkan ambang prediksi sehingga recall meningkat; pantau trade-off dengan precision dan beban operasional.
3. Biaya ekonomi dari kesalahan klasifikasi
Lakukan analisis cost-benefit: hitung biaya rata-rata akibat false negative (kerugian kredit) vs biaya false positive (mis. kehilangan pendapatan atau biaya pengecekan). Optimalkan model terhadap metrik biaya-ekonomi bukan sekadar AUC.
4. Intervensi proaktif yang disarankan
Bagi pelanggan yang diprediksi berisiko (meskipun beberapa false positives ada), terapkan intervensi ringan: notifikasi pengingat pembayaran, penjadwalan ulang cicilan, pembatasan sebagian transaksi, atau program restrukturisasi. Gunakan pendekatan bertingkat (tiered intervention) agar biaya penanganan efisien.
5. Integrasi Explainability
Terapkan SHAP atau LIME untuk menjelaskan alasan prediksi per nasabah (mis. “tinggi karena *PAY_1=2* dan *BILL_AMT1* besar”), sehingga tim risiko dapat memutuskan tindakan yang tepat dan dipertanggungjawabkan.

KESIMPULAN DAN SARAN

Kesimpulan

Model *deep learning* yang dibangun menunjukkan kemampuan prediksi yang baik secara keseluruhan (accuracy $\approx 81.6\%$, AUC ≈ 0.771), terutama dalam mengidentifikasi nasabah non-default (specificity $\approx 94.4\%$). Namun, rendahnya *recall* ($\sim 36.5\%$) mengindikasikan bahwa model saat ini berisiko melewatkan banyak kasus *default* suatu kelemahan kritis dalam konteks manajemen risiko.

Saran

Sebelum adopsi operasional, disarankan melakukan penyesuaian threshold, optimasi untuk memprioritaskan recall jika tujuan adalah mitigasi kerugian, serta integrasi model dengan kebijakan bisnis dan teknik *explainable AI* agar keputusan yang diambil dapat diinterpretasikan dan diimplementasikan oleh tim manajemen keuangan digital.

DAFTAR PUSTAKA

- Barroso, M., & Laborda, J. (2022). Digital transformation and the emergence of the Fintech sector: Systematic literature review. *Digital Business*, 2(2). <https://doi.org/10.1016/j.digbus.2022.100028>
- Căvescu, A. M., & Popescu, N. (2025). Predictive Analytics in Human Resources Management: Evaluating AIHR's Role in Talent Retention. In *AppliedMath* (Vol. 5, Issue 3). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/appliedmath5030099>
- Cha, G. W., Moon, H. J., & Kim, Y. C. (2021). Comparison of random forest and gradient boosting machine models for predicting demolition waste based on small datasets and categorical variables. *International Journal of Environmental Research and Public Health*, 18(16). <https://doi.org/10.3390/ijerph18168530>
- Chang, V., Sivakulasingam, S., Wang, H., Wong, S. T., Ganatra, M. A., & Luo, J. (2024). Credit Risk Prediction Using Machine Learning and Deep Learning: A Study on Credit Card Customers. *Risks*, 12(11). <https://doi.org/10.3390/risks12110174>
- Chen, F., Yu, D., & Sun, Z. (2023). Investigating the associations of consumer financial knowledge and financial behaviors of credit card use. *Heliyon*, 9(1). <https://doi.org/10.1016/j.heliyon.2022.e12713>
- Haoran, X., Wenlong, M., & Siyu, Z. (2024). Digital technology development and systemic financial risks: Evidence from 22 countries. In *Borsa Istanbul Review* (Vol. 24, pp. 1–9). Borsa Istanbul Anonim Sirketi. <https://doi.org/10.1016/j.bir.2024.08.002>
- Huang, H., Li, J., Zheng, C., Chen, S., Wang, X., & Chen, X. (2025). Advanced Default Risk Prediction in Small and Medium-Sized Enterprises Using Large Language Models. *Applied Sciences (Switzerland)*, 15(5). <https://doi.org/10.3390/app15052733>
- Mihaela, R., Chireac, N., Nioață, R.-M., & Chireac, (. (2025). THE IMPACT OF DIGITALIZATION ON BANKING EFFICIENCY: AUTOMATION, SECURITY AND CUSTOMER EXPERIENCE. *Article in International Journal of Latest Engineering and Management Research*. <https://www.researchgate.net/publication/389264542>
- Septian, F. (2024). Indonesian Journal Of Information Technology Optimasi Klusterisasi pada Lama Tempo Pekerjaan Berbasis Gradient Boost Algorithm. *INDONESIAN JOURNAL OF INFORMATION TECHNOLOGY*. <https://doi.org/10.25077/Attribution-NonCommercial>
- Supriadi, I., Maghfiroh, R. U., & Abadi, R. (2025). Implementing Innovative Credit Scoring (ICS) for Credit Risk Assessment and Loan Origination. *The International Journal of Financial Systems*, 3(1), 99–112. <https://doi.org/10.61459/ijfs.v3i1.36>
- Suryono, R. R., Budi, I., & Purwandari, B. (2020). Challenges and trends of financial technology (Fintech): A systematic literature review. In *Information (Switzerland)* (Vol. 11, Issue 12, pp. 1–20). MDPI AG. <https://doi.org/10.3390/info11120590>
- Tian, Y., Xu, S., Cao, Y., Wang, Z., & Wei, Z. (2025). An Empirical Comparison of Machine Learning and Deep Learning Models for Automated Fake News Detection. *Mathematics*, 13(13). <https://doi.org/10.3390/math13132086>