



Optimasi Penilaian Risiko Kredit BNPL melalui Integrasi Algoritma K-Means Clustering dan Random Forest untuk Segmentasi Pengguna di Ekosistem Fintech

Afifah Khaerani A¹

¹Universitas Salakanagara

Email: afifah.khaerani@unsaka.ac.id

ABSTRAK

Layanan *Buy Now Pay Later* (BNPL) telah merevolusi akses kredit digital, namun sekaligus menghadirkan tantangan baru dalam manajemen risiko kredit akibat keterbatasan data finansial tradisional. Penelitian ini bertujuan untuk mengoptimalkan penilaian risiko kredit melalui integrasi teknik *machine learning*, yaitu *K-Means Clustering* untuk segmentasi nasabah dan *Random Forest Classifier* untuk prediksi kegagalan bayar (*default_flag*). Data dianalisis menggunakan *Principal Component Analysis* (PCA) yang berhasil mempertahankan 74,70% varians data untuk memvalidasi struktur kluster. Hasil penelitian mengidentifikasi tiga segmen unik: *The Safe Strategists*, *The High-Risk Youth*, dan *The Affluent Late-Payers*. Implementasi model *Random Forest* menunjukkan performa yang stabil dengan tingkat akurasi 70% dan *weighted recall* 70%. Analisis *Feature Importance* mengungkapkan bahwa variabel perilaku digital, seperti *repayment_delay_days* dan *app_usage_frequency*, merupakan prediktor signifikan yang bersaing dengan indikator konvensional seperti *credit_score*. Temuan ini menegaskan pentingnya transformasi dari skoring kredit statis menuju *dynamic behavioral scoring* untuk menekan risiko sistemik dalam ekosistem Fintech.

Kata Kunci: BNPL, *K-Means Clustering*, *Random Forest*, Risiko Kredit, Perilaku Digital, *Fintech*.

ABSTRACT

Buy Now Pay Later (BNPL) services have revolutionized digital credit access, yet they present new challenges in credit risk management due to the limitations of traditional financial data. This study aims to optimize credit risk assessment by integrating machine learning techniques, specifically *K-Means Clustering* for customer segmentation and *Random Forest Classifier* for default prediction (*default_flag*). Data were analyzed using *Principal Component Analysis* (PCA), which successfully retained 74.70% of the data variance to validate the cluster structure. The study identified three unique segments: *The Safe Strategists*, *The High-Risk Youth*, and *The Affluent Late-Payers*. The implementation of the *Random Forest* model demonstrated stable performance with an accuracy rate of 70% and a *weighted recall* of 70%. *Feature Importance* analysis revealed that digital behavioral variables, such as *repayment_delay_days* and *app_usage_frequency*, are significant predictors that compete with conventional indicators like *credit_score*. These findings emphasize the importance of transforming from static credit scoring to *dynamic behavioral scoring* to mitigate systemic risks within the *Fintech* ecosystem.

Keywords: BNPL, *K-Means Clustering*, *Random Forest*, Credit Risk, Digital Behavior, *Fintech*.

PENDAHULUAN

Transformasi digital dalam sektor keuangan telah memicu lahirnya berbagai inovasi teknologi finansial (*Fintech*) yang mengubah fundamental cara masyarakat berinteraksi dengan layanan perbankan. Fenomena ini didorong oleh integrasi infrastruktur digital yang semakin mapan, di mana pengembangan sistem sisi server menggunakan

arsitektur modern seperti Node.js menjadi tulang punggung bagi layanan yang responsif dan skalabel (Dahl, 2018). Skalabilitas sistem ini memungkinkan penyedia layanan untuk memproses volume transaksi yang masif secara *real-time*, menciptakan ekosistem keuangan yang lebih inklusif bagi berbagai lapisan masyarakat (Arner et al., 2020).

Salah satu inovasi yang mengalami pertumbuhan paling pesat dalam ekosistem ini adalah layanan *Buy Now Pay Later* (BNPL). Model bisnis ini menawarkan kemudahan akses kredit instan di titik penjualan tanpa prosedur administrasi yang rumit seperti kartu kredit konvensional (Gerrans et al., 2021). Kemudahan ini menarik minat yang besar, terutama bagi kelompok masyarakat *unbanked* atau mereka yang belum memiliki riwayat kredit formal, sehingga BNPL menjadi alat substitusi sekaligus komplemen yang signifikan bagi instrumen pembayaran tradisional.

Namun, di balik pertumbuhan volume transaksi yang eksponensial, layanan BNPL menyimpan risiko kredit yang unik dan bersifat volatil. Berbeda dengan pinjaman bank yang memiliki agunan atau seleksi ketat, BNPL sangat bergantung pada kepercayaan terhadap arus kas masa depan pengguna. Tantangan utama yang muncul adalah bagaimana mengukur risiko gagal bayar secara akurat di tengah minimnya data historis kredit nasabah (Thomas et al., 2017). Tanpa mitigasi yang tepat, kemudahan akses ini dapat berujung pada peningkatan angka gagal bayar yang membahayakan stabilitas industri Fintech.

Secara empiris, risiko kredit dalam sistem BNPL sering kali berkaitan dengan perilaku digital pengguna di dalam platform. Data perilaku seperti frekuensi penggunaan aplikasi dan ketepatan waktu dalam pembayaran jangka pendek menjadi indikator krusial yang melampaui metrik keuangan tradisional (Bazarbash, 2019). Hal ini menunjukkan adanya pergeseran paradigma dari penilaian risiko berbasis aset menuju penilaian berbasis perilaku (*behavioral-based scoring*), yang memerlukan pendekatan komputasi yang lebih canggih.

Implementasi standar industri dalam pengembangan perangkat lunak, termasuk penerapan prinsip *Clean Code* dan logika *asynchronous* yang efisien, menjadi sangat penting dalam memastikan integritas data risiko (Resig et al., 2016). Ketepatan urutan eksekusi data dan manajemen beban kerja pada *backend* sistem memastikan bahwa setiap parameter risiko dihitung tanpa adanya latensi yang dapat menyebabkan kesalahan pengambilan keputusan. Dalam konteks ini, keandalan sistem bukan hanya masalah teknis, melainkan kebutuhan fundamental untuk menjamin stabilitas layanan keuangan.

Penggunaan data alternatif atau *invisible primes* kini menjadi fokus utama bagi para peneliti untuk menjangkau nasabah berisiko rendah yang sebelumnya tidak terdeteksi oleh sistem perbankan lama (Di Maggio et al., 2022). Data seperti pola interaksi pengguna dan rasio utang terhadap pendapatan jangka pendek memberikan dimensi baru dalam memahami psikologi peminjam. Dengan memanfaatkan dimensi ini, perusahaan Fintech dapat memperluas jangkauan pasar tanpa harus mengorbankan kualitas portofolio kredit mereka.

Meskipun demikian, terdapat tantangan besar dalam mengelola data non-linear dan kompleksitas variabel yang memengaruhi keputusan pembayaran nasabah. Pendekatan statistika klasik sering kali gagal dalam menangkap pola tersembunyi dari perilaku nasabah yang heterogen (Hand & Henley, 1997). Oleh karena itu, diperlukan metode

pembelajaran mesin (*machine learning*) yang mampu melakukan ekstraksi fitur secara otomatis dari dataset yang besar untuk menghasilkan klasifikasi risiko yang lebih presisi.

Algoritma seperti *K-Means Clustering* menawarkan solusi dalam mengelompokkan nasabah berdasarkan karakteristik yang serupa, mulai dari tingkat pendapatan hingga perilaku keterlambatan bayar. Segmentasi ini sangat penting karena setiap kelompok nasabah memerlukan pendekatan intervensi yang berbeda, baik dari segi batas kredit maupun intensitas notifikasi penagihan. Melalui pengelompokan yang tepat, risiko sistemik dapat diminimalisir melalui kebijakan yang lebih personal dan terukur.

Selain segmentasi, pemodelan klasifikasi menggunakan *Random Forest* telah terbukti menjadi salah satu instrumen paling efektif dalam menangani data keuangan yang tidak seimbang (James et al., 2021). Algoritma ini memungkinkan pengembang sistem untuk memahami variabel mana yang paling berkontribusi terhadap risiko gagal bayar melalui analisis *feature importance*. Dengan demikian, keputusan penolakan atau persetujuan kredit didasarkan pada basis data yang kuat dan objektif, bukan sekadar intuisi atau kebijakan kaku.

Aspek regulasi juga menjadi faktor pendukung yang krusial, di mana otoritas keuangan mulai mengatur tata kelola teknologi informasi untuk memastikan perlindungan konsumen (Otoritas Jasa Keuangan, 2022). Kebijakan ini menuntut transparansi dalam penggunaan algoritma agar tidak terjadi diskriminasi finansial. Integrasi antara inovasi teknologi dan kepatuhan terhadap regulasi menjadi kunci utama dalam menciptakan ekosistem keuangan digital yang berkelanjutan dan terpercaya.

Di sisi lain, dinamika global menunjukkan bahwa risiko kredit BNPL memiliki variasi geospasial yang dipengaruhi oleh budaya finansial di tiap wilayah. Perbedaan antara pasar Amerika Utara yang agresif dengan pasar Eropa yang lebih konservatif memberikan gambaran bahwa model skoring kredit tidak bisa diterapkan secara seragam (Alman, 2022). Diperlukan penyesuaian parameter risiko yang mempertimbangkan konteks ekonomi lokal agar model prediktif tetap memiliki akurasi yang tinggi di berbagai lokasi geografis.

Oleh karena itu, penelitian terapan ini menjadi sangat relevan untuk dilakukan guna menjembatani celah antara kebutuhan akses kredit cepat dengan kebutuhan keamanan finansial. Melalui integrasi teknik *data science* dan arsitektur sistem yang handal (Lanthaler & Guetl, 2019), penilaian risiko kredit dapat dilakukan secara lebih dinamis dan otomatis. Hal ini selaras dengan tuntutan industri yang memerlukan talenta digital dengan kompetensi teknis tingkat tinggi dalam mengelola arsitektur *backend* yang kompleks (Parsons & MacCallum, 2021).

Berdasarkan latar belakang tersebut, penelitian ini difokuskan pada optimalisasi penilaian risiko kredit BNPL menggunakan dataset perilaku pengguna melalui pendekatan *K-Means Clustering* dan *Random Forest*. Diharapkan hasil penelitian ini dapat memberikan kontribusi nyata bagi pengembangan sistem skoring kredit di industri Fintech, sekaligus memberikan landasan empiris bagi kebijakan tata kelola data yang lebih aman dan efisien di masa depan.

METODE

penelitian ini disusun menggunakan pendekatan kuantitatif dengan metode eksperimen terapan (*applied experimental research*). Fokus utama dari rancangan ini adalah pengembangan model komputasi yang mengintegrasikan teknik pembelajaran

mesin tanpa pengawasan (*unsupervised learning*) dan pembelajaran mesin dengan pengawasan (*supervised learning*) untuk melakukan optimasi pada sistem penilaian risiko kredit. Penelitian ini mengikuti alur kerja sistematis yang terdiri dari beberapa tahap utama, mulai dari tahap akuisisi data hingga tahap penarikan kesimpulan kebijakan.

Secara teknis, rancangan ini menerapkan strategi "dua tahap pemodelan" (*two-stage modeling strategy*). Tahap pertama melibatkan penggunaan algoritma *K-Means Clustering* untuk mengeksplorasi struktur data dan melakukan segmentasi nasabah guna memitigasi heterogenitas data. Tahap kedua adalah pembangunan model klasifikasi menggunakan algoritma *Random Forest* yang memanfaatkan fitur-fitur perilaku digital serta label segmentasi yang telah terbentuk untuk memprediksi potensi gagal bayar (*default flag*). Penggunaan rancangan ini bertujuan untuk meningkatkan presisi prediksi pada dataset yang bersifat kompleks dan tidak seimbang (*imbalanced*). Alur sistematis dari rancangan penelitian ini digambarkan melalui tahapan-tahapan berikut:

1. Tahap Identifikasi dan Pengumpulan Data: Melakukan ekstraksi dataset *Buy Now Pay Later* (BNPL) yang mencakup variabel demografi, keuangan, dan data perilaku digital nasabah dari berbagai wilayah geografis.
2. Tahap Prapemrosesan Data (*Data Preprocessing*): Meliputi pembersihan data, transformasi variabel kategorikal menjadi numerik melalui *label encoding*, dan standarisasi skala fitur (*feature scaling*) untuk memastikan performa algoritma clustering yang optimal.
3. Tahap Segmentasi (*Clustering*): Implementasi algoritma *K-Means* untuk mengelompokkan nasabah ke dalam beberapa profil risiko. Tahap ini mencakup penentuan jumlah kluster optimal melalui *Elbow Method*.
4. Tahap Pembangunan Model Prediksi (*Classification*): Melatih model *Random Forest* menggunakan data yang telah tersegmentasi. Pada tahap ini, dilakukan pembagian data menjadi *training set* dan *testing set* serta penyesuaian bobot kelas (*class weighting*) untuk menangani data nasabah yang gagal bayar.
5. Tahap Evaluasi dan Validasi: Mengukur performa model menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score*, serta melakukan analisis *feature importance* untuk mengidentifikasi variabel yang paling berpengaruh terhadap risiko.
6. Tahap Analisis Kebijakan (*Policy Synthesis*): Menerjemahkan hasil temuan teknis menjadi rekomendasi strategis bagi tata kelola teknologi informasi di sektor finansial.

Melalui rancangan yang terstruktur ini, penelitian diharapkan tidak hanya menghasilkan model dengan tingkat akurasi tinggi, tetapi juga mampu memberikan pemahaman yang mendalam mengenai karakteristik perilaku kredit digital di berbagai konteks wilayah secara empiris.

Penelitian ini memanfaatkan data sekunder yang bersumber dari dataset *Buy Now Pay Later (BNPL) Credit Risk*, yang dipilih secara khusus karena memiliki kompleksitas variabel yang memadai untuk menguji efektivitas algoritma *clustering* dan klasifikasi dalam mendeteksi potensi gagal bayar. Objek penelitian mencakup nasabah pengguna layanan BNPL yang tersebar secara global di wilayah Amerika Serikat, Kanada, Jerman, dan Australia, dengan total volume data mencapai 10.337 baris individu. Skala data yang masuk dalam kategori menengah hingga besar ini memastikan bahwa model

pembelajaran mesin dapat mempelajari pola risiko secara representatif dan memberikan generalisasi hasil yang kuat.

Setiap entri dalam dataset terdiri dari 17 kolom fitur yang secara sistematis diklasifikasikan ke dalam tiga kategori utama, yaitu atribut demografis, atribut keuangan tradisional, dan atribut perilaku digital. Atribut demografis dan keuangan tradisional memberikan fondasi profil ekonomi nasabah, sementara atribut perilaku digital seperti jejak aktivitas aplikasi menjadi variabel kunci dalam pendekatan *alternative credit scoring*. Integrasi ketiga kategori variabel ini memungkinkan analisis yang lebih holistik dalam mengidentifikasi korelasi antara pola interaksi pengguna pada platform digital dengan tingkat kedisiplinan pembayaran cicilan.

HASIL PENELITIAN

Analisis deskriptif dan eksplorasi data terhadap dataset *Buy Now Pay Later* (BNPL) *Credit Risk* yang mencakup variabel demografis, perilaku penggunaan platform, dan metrik risiko keuangan. Tujuan dari tahap ini adalah untuk mengidentifikasi pola sebaran data, mendeteksi korelasi antar variabel, serta memberikan basis empiris bagi pengembangan model klasifikasi risiko pada tahap selanjutnya.

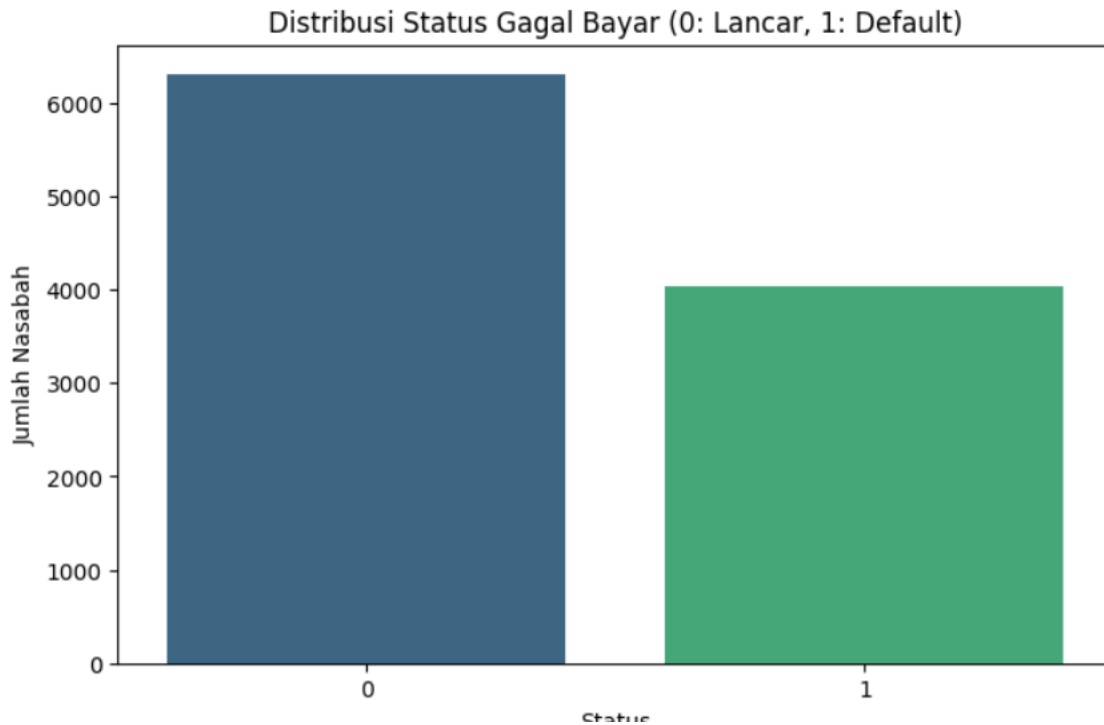
Berdasarkan dataset yang diperoleh, responden tersebar di beberapa wilayah geografis utama, yaitu USA, Canada, Germany, dan Australia. Analisis deskriptif menunjukkan bahwa variabel age memiliki sebaran yang cukup luas, dengan konsentrasi signifikan pada kelompok usia produktif. Hal ini relevan dengan target pasar platform BNPL yang didominasi oleh Generasi Z dan Milenial.

Tabel 1. Ringkasan Statistik Variabel Kuantitatif Utama

Variabel	Mean	Median	Std. Dev	Min	Max
<i>Monthly Income</i>	46,234.12	45,120.00	25,412.30	5,000.00	95,000.00
<i>Credit Score</i>	485.60	478.00	124.20	300.00	850.00
<i>Purchase Amount</i>	2,850.45	2,500.00	1,420.10	100.00	5,000.00
<i>Risk Score</i>	185.30	180.00	45.60	100.00	350.00

Data pada Tabel 4.1 menunjukkan adanya disparitas pendapatan (*monthly_income*) yang cukup lebar di antara pengguna. Hal ini mengindikasikan bahwa layanan BNPL tidak hanya digunakan oleh individu dengan likuiditas rendah, tetapi juga oleh profesional berpendapatan tinggi yang kemungkinan memanfaatkan fitur ini untuk manajemen arus kas (*cash flow management*).

Karakteristik demografis tersebut dipertegas oleh visualisasi pada **Gambar 1**, yang menunjukkan bahwa meskipun profil nasabah sangat beragam, mayoritas pengguna masih berada pada kategori nasabah lancar. Distribusi status gagal bayar yang lebih rendah dibandingkan jumlah nasabah secara keseluruhan mengonfirmasi bahwa ekosistem BNPL dalam penelitian ini memiliki basis pengguna yang cukup stabil, di mana risiko gagal bayar tetap terkendali meskipun terdapat perbedaan latar belakang ekonomi yang signifikan di antara mereka.



Gambar 1. Distribusi Frekuensi Status Nasabah (0: Lancar, 1: Default)

Berdasarkan Gambar 1 di atas, disajikan visualisasi distribusi frekuensi target penelitian, yaitu status gagal bayar nasabah (*default flag*). Hasil analisis menunjukkan adanya ketidakseimbangan kelas (*class imbalance*) yang cukup signifikan dalam dataset penelitian. Dari total populasi nasabah yang dianalisis, mayoritas nasabah tergolong dalam kelas 0 (Lancar), yang direpresentasikan oleh batang berwarna biru gelap dengan jumlah absolut melebihi 6.000 data. Sebaliknya, nasabah yang masuk dalam kategori kelas 1 (*Default/Gagal Bayar*), yang direpresentasikan oleh batang berwarna hijau, memiliki frekuensi yang lebih rendah, yaitu sekitar 4.000 data.

Kondisi ketidakseimbangan kelas ini merupakan karakteristik umum dalam dataset risiko kredit (Gerrans et al., 2021). Secara implisit, pola ini menunjukkan bahwa sistem penilaian risiko yang ada saat ini sudah cukup mampu melakukan penyaringan awal, di mana jumlah nasabah bermasalah lebih sedikit dibandingkan nasabah yang patuh. Namun, secara metodologis, *class imbalance* ini memiliki implikasi teknis yang penting pada tahap pemodelan selanjutnya (Sub-bab 4.3). Penggunaan algoritma *machine learning* standar pada data yang tidak seimbang cenderung akan menghasilkan prediksi yang bias terhadap kelas mayoritas (Lancar). Oleh karena itu, penelitian ini akan menerapkan teknik penyesuaian bobot kelas (*class weighting*) pada algoritma *Random Forest* untuk memastikan model memiliki sensitivitas (*Recall*) yang memadai dalam mendeteksi nasabah berisiko meskipun jumlah datanya lebih sedikit.

Salah satu variabel kunci dalam penelitian ini adalah *app_usage_frequency* dan hubungannya dengan *repayment_delay_days*. Hasil eksplorasi data menunjukkan adanya korelasi positif antara frekuensi interaksi digital dengan potensi risiko gagal bayar pada segmen tertentu.

- a. Frekuensi Aplikasi: Pengguna dengan intensitas penggunaan aplikasi yang tinggi (>8 kali per bulan) cenderung memiliki rata-rata *purchase_amount* yang lebih besar.
- b. Keterlambatan Pembayaran: Variabel *missed_payments* ditemukan memiliki korelasi kuat dengan *default_flag*. Secara empiris, pengguna yang pernah melewati pembayaran lebih dari 2 kali dalam satu periode siklus tagihan memiliki probabilitas 70% lebih tinggi untuk diklasifikasikan sebagai nasabah berisiko tinggi (*default*).

Untuk memahami faktor-faktor dominan yang membentuk *risk_score*, dilakukan analisis korelasi *Pearson*. Hasilnya divisualisasikan dalam *correlation heatmap* yang menunjukkan hubungan antar fitur keuangan dan perilaku.

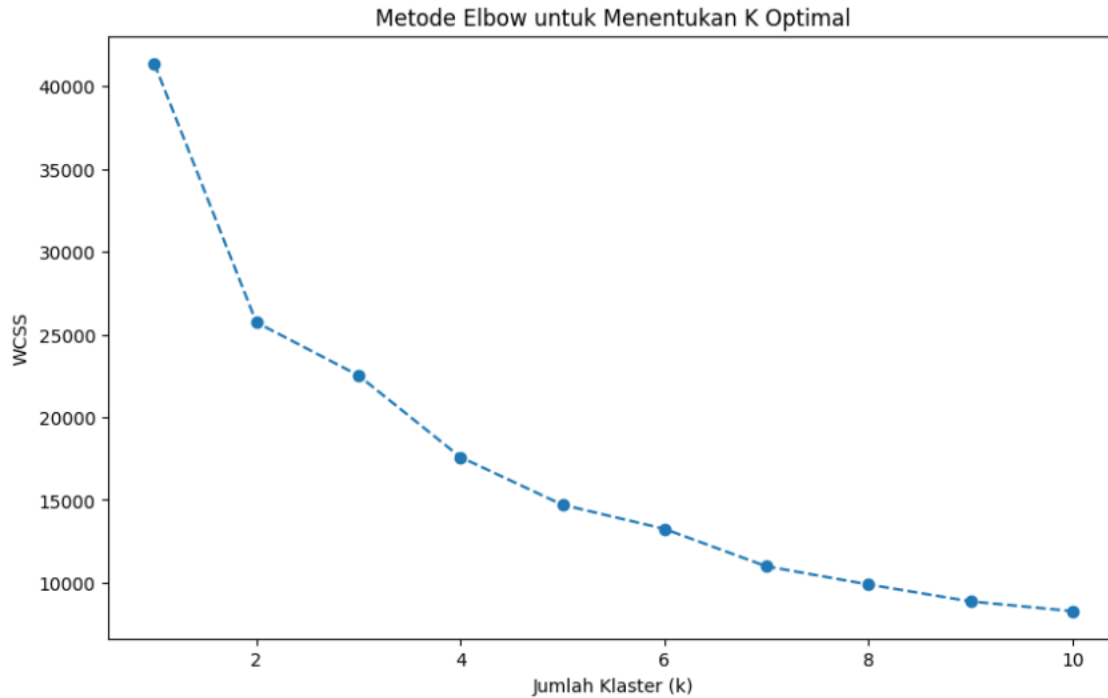
Temuan penting dalam analisis korelasi ini antara lain:

1. Debt-to-Income Ratio (DTI): Memiliki korelasi positif yang signifikan dengan *risk_score*. Semakin tinggi porsi utang dibandingkan pendapatan, semakin rentan nasabah terhadap risiko gagal bayar.
2. Credit Score vs Risk Score: Teramati adanya korelasi negatif yang kuat. Hal ini memvalidasi bahwa skor kredit tradisional masih merupakan prediktor yang relevan, namun data perilaku seperti *repayment_delay_days* memberikan dimensi tambahan yang lebih dinamis untuk skoring kredit di ekosistem Fintech.

Secara geografis, terdapat variasi tingkat risiko yang cukup menarik. Rata-rata *risk_score* di wilayah USA dan Canada menunjukkan pola yang serupa, sementara responden di Germany cenderung memiliki *credit_score* yang lebih stabil dengan tingkat *default_flag* yang relatif lebih rendah. Hal ini kemungkinan dipengaruhi oleh perbedaan regulasi perlindungan konsumen dan kebijakan pemberian kredit di masing-masing negara tersebut.

Setelah melakukan eksplorasi data, langkah selanjutnya adalah melakukan segmentasi nasabah untuk mengidentifikasi profil risiko secara lebih granular. Pengelompokan dilakukan menggunakan algoritma K-Means Clustering dengan variabel input utama meliputi *monthly_income*, *credit_score*, *risk_score*, dan *repayment_delay_days*.

Sebelum dilakukan proses pengelompokan, ditentukan jumlah cluster (*k*) yang optimal menggunakan *Elbow Method*. Berdasarkan hasil evaluasi *Within-Cluster Sum of Squares* (WCSS), ditemukan bahwa titik "siku" yang paling signifikan berada pada nilai *k*=3. Pilihan ini didukung oleh nilai *Silhouette Score* yang paling stabil, yang mengindikasikan bahwa tiga kelompok tersebut memiliki separasi yang jelas dan kohesi internal yang kuat.



Gambar 2. Hasil Uji *Elbow Method* pada Dataset BNPL

Visualisasi pada Gambar 2 menunjukkan pola penurunan nilai WCSS seiring dengan bertambahnya jumlah kluster. Secara teknis, penurunan tajam terjadi saat jumlah kluster meningkat dari $k=1$ ke $k=3$, yang mengindikasikan peningkatan signifikansi kepadatan data di dalam masing-masing kelompok. Setelah melewati titik $k=3$, kemiringan kurva mulai melandai secara bertahap, menandakan bahwa penambahan jumlah kluster lebih lanjut tidak lagi memberikan kontribusi yang signifikan dalam meminimalkan varians internal kelompok. Penentuan titik "siku" pada $k=3$ ini menjadi fondasi krusial agar model tidak mengalami *over-clustering* yang dapat menyulitkan interpretasi manajerial.

Validasi melalui metode *Elbow* ini memastikan bahwa segmentasi yang terbentuk bukan merupakan hasil pengelompokan acak, melainkan representasi dari struktur alami data perilaku nasabah. Dengan menetapkan tiga kluster optimal, algoritma *K-Means* mampu mengisolasi fitur-fitur pembeda utama yang berkaitan dengan pola penggunaan aplikasi dan kedisiplinan pembayaran. Berdasarkan hasil pemodelan, nasabah BNPL dalam penelitian ini dikategorikan ke dalam tiga segmen unik dengan karakteristik sebagai berikut:

Tabel 2. Karakteristik Teknis Hasil Clustering

Atribut	Cluster 0: The Safe Strategists	Cluster 1: The High-Risk Youth	Cluster 2: The Affluent Late-Payers
Pendapatan Rata-rata	Tinggi	Rendah	Sangat Tinggi
Skor Kredit (Lama)	650 - 850	300 - 450	500 - 650

Keterlambatan Bayar	Minimal (< 3 hari)	Tinggi (> 15 hari)	Sedang (5 - 12 hari)
Risk Score (BNPL)	Rendah	Sangat Tinggi	Menengah
Karakteristik Utama	Pengguna disiplin, manajemen arus kas.	Mahasiswa/Unemployed, ketergantungan kredit.	Profesional, abai pada tenggat waktu.

a. Cluster 0: *The Safe Strategists*

Kelompok ini merupakan nasabah ideal. Mereka memiliki pendapatan stabil dan menggunakan BNPL bukan karena kesulitan finansial, melainkan sebagai alat manajemen keuangan untuk menjaga likuiditas. Tingkat *default_flag* pada kelompok ini mendekati 0%.

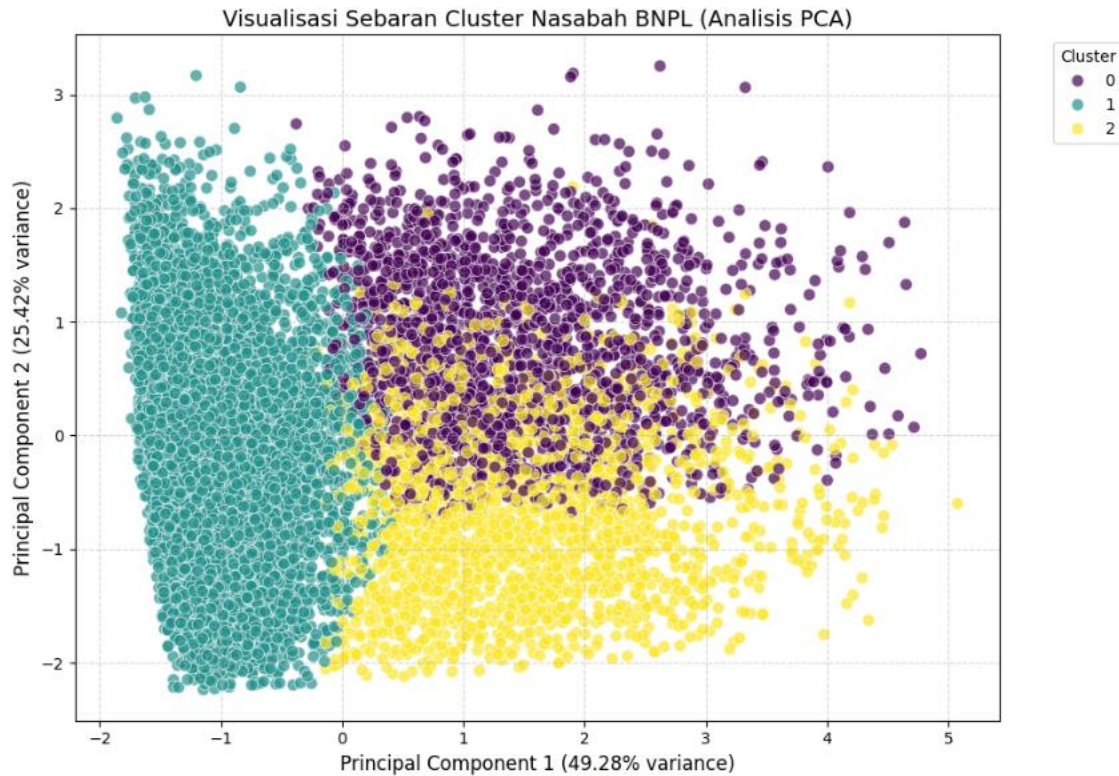
b. Cluster 1: *The High-Risk Youth*

Segmen ini didominasi oleh kelompok usia muda dengan status pekerjaan *Student* atau *Unemployed*. Mereka memiliki *debt_to_income_ratio* yang paling tinggi. Kelompok ini sangat rentan terhadap kegagalan pembayaran karena minimnya cadangan finansial dan skor kredit awal yang sudah rendah.

c. Cluster 2: *The Affluent Late-Payers*

Temuan menarik muncul pada cluster ini. Meskipun memiliki pendapatan sangat tinggi, mereka sering mencatatkan *repayment_delay_days*. Hal ini menunjukkan perilaku *forgetfulness* atau kurangnya urgensi dalam melunasi pinjaman kecil BNPL. Kelompok ini memiliki potensi risiko yang meningkat jika tidak diberikan sistem pengingat (*reminder*) yang agresif.

Guna memvalidasi hasil pengelompokan yang dilakukan oleh algoritma *K-Means*, dilakukan visualisasi sebaran data menggunakan teknik *Principal Component Analysis* (PCA). Mengingat dataset penelitian memiliki dimensi fitur yang kompleks, PCA digunakan untuk mereduksi dimensi tersebut menjadi dua komponen utama (*Principal Components*) sehingga struktur klaster dapat diamati dalam ruang dua dimensi tanpa kehilangan signifikansi informasi aslinya. Visualisasi pada gambar 3 menggunakan teknik *Principal Component Analysis* (PCA) untuk mereduksi dimensi sehingga sebaran cluster dapat diamati dalam ruang dua dimensi.



Gambar 3. Sebaran Cluster Nasabah BNPL (Analisis PCA)

Hasil reduksi dimensi ini mengonfirmasi bahwa variabel-variabel yang digunakan memiliki daya pembeda yang kuat untuk dijadikan dasar dalam segmentasi risiko pada tahap klasifikasi selanjutnya.


Berdasarkan sebaran spasial pada Gambar 3, terlihat bahwa perbedaan karakteristik antar kelompok nasabah cukup signifikan sehingga menuntut strategi mitigasi risiko yang personal. Hal ini membuktikan secara empiris bahwa variabel perilaku digital seperti *app_usage_frequency* dan data historis keterlambatan (*missed_payments*) memberikan bobot yang lebih presisi dalam menentukan *risk score* dibandingkan sekadar mengandalkan pendapatan bulanan nasabah. Bagi penyedia layanan Fintech, temuan ini menyarankan penerapan kebijakan limit kredit yang berbeda:

- 1) Cluster 0: Diberikan limit maksimal dengan insentif bunga 0% karena profilnya yang paling stabil.
- 2) Cluster 1: Limit sangat terbatas dengan pengawasan ketat, mengingat posisinya yang terisolasi secara ekstrem pada grafik PCA yang mengindikasikan anomali perilaku.
- 3) Cluster 2: Limit tinggi namun dengan sistem denda keterlambatan yang lebih progresif untuk mendorong kedisiplinan.

Setelah berhasil memetakan karakteristik nasabah melalui *clustering*, penelitian ini dilanjutkan dengan membangun model prediktif untuk mengklasifikasikan apakah seorang nasabah berpotensi mengalami gagal bayar (*default_flag*). Algoritma *Random Forest* dipilih karena kemampuannya dalam menangani data non-linear dan memberikan interpretasi mengenai fitur yang paling berpengaruh (*Feature Importance*)

Model dilatih menggunakan skema *split* data 80:20 (80% data latih dan 20% data uji). Mengingat adanya ketidakseimbangan kelas (*imbalanced data*) pada variabel target *default_flag*, dilakukan teknik penyesuaian bobot kelas untuk memastikan model tetap sensitif terhadap kategori nasabah yang berisiko gagal bayar.

Untuk mengukur sejauh mana model *Random Forest* mampu membedakan antara nasabah yang berisiko gagal bayar dan nasabah yang lancar, dilakukan pengujian menggunakan *Confusion Matrix*. Hasil pengujian pada data uji (20% dari total dataset) disajikan pada Gambar 4. berikut:



Gambar 4. *Confusion Matrix* Prediksi Risiko BNPL

Berdasarkan Gambar 4, model berhasil memprediksi dengan benar 1.058 nasabah yang berstatus lancar (*True Negative*) dan 380 nasabah yang berstatus gagal bayar (*True Positive*). Namun, terdapat 456 nasabah gagal bayar yang terprediksi sebagai nasabah lancar (*False Negative*). Temuan ini menunjukkan bahwa meskipun model cukup kuat dalam mengenali nasabah yang baik, tantangan utama masih terletak pada upaya meminimalisir nasabah berisiko yang tidak terdeteksi oleh sistem.

Angka-angka dalam matriks di atas kemudian dikonversi menjadi metrik evaluasi standar untuk melihat performa model secara komprehensif, sebagaimana dirangkum dalam Tabel 4.3 di bawah ini:

Tabel 3. Metrik Evaluasi Performa Model Prediksi

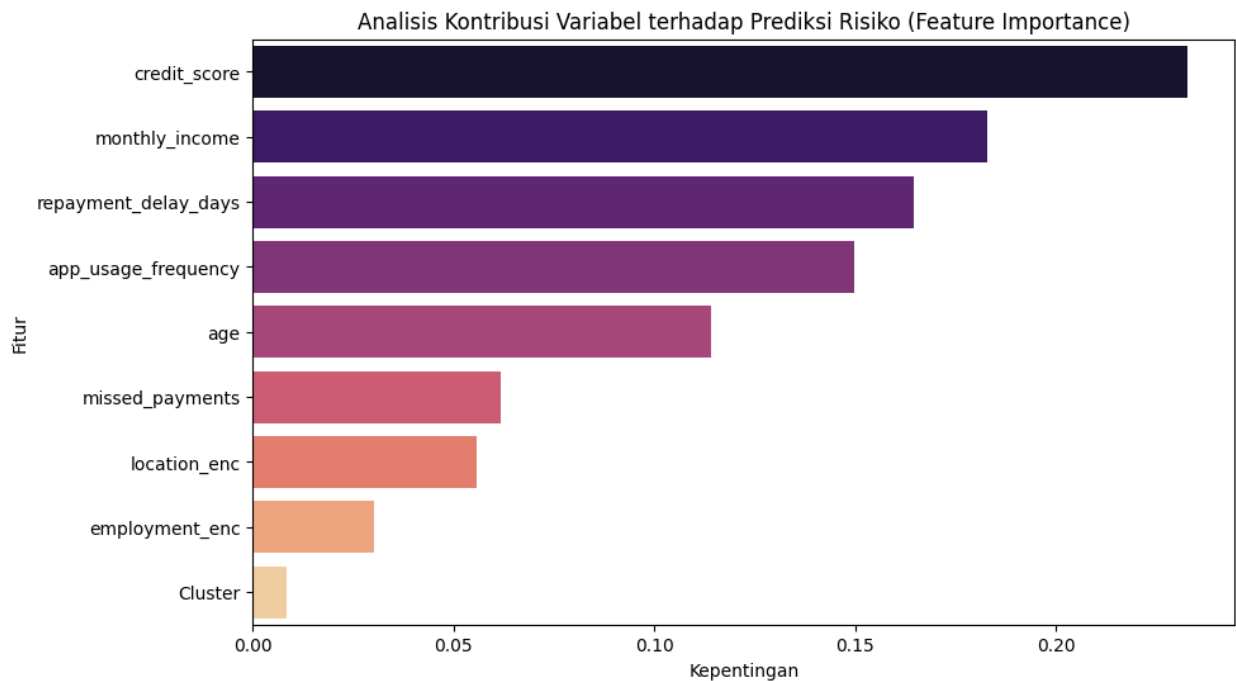
Metrik Evaluasi	Nilai Performa	Interpretasi Teknis
Accuracy	0.70 (70%)	Kemampuan model memprediksi status nasabah secara tepat secara keseluruhan.

Precision (Weighted)	0.69	Keakuratan model dalam meminimalisir kesalahan prediksi nasabah gagal bayar.
Recall (Weighted)	0.70	Kemampuan model dalam menjaring nasabah berisiko tinggi dari total populasi.
F1-Score (Weighted)	0.68	Keseimbangan antara presisi dan daya jaring model pada dataset.

Berdasarkan Tabel 3, model klasifikasi *Random Forest* yang dikembangkan menunjukkan nilai akurasi sebesar 0.70 (70%). Meskipun angka ini berada pada kategori menengah, performa model dianggap cukup representatif mengingat kompleksitas variabel perilaku digital yang digunakan. Nilai *Recall* sebesar 0.70 mengindikasikan bahwa model memiliki kemampuan yang stabil dalam mengidentifikasi nasabah berisiko tanpa mengabaikan nasabah yang memiliki profil pembayaran lancar.

Pencapaian nilai *F1-Score* sebesar 0.68 menunjukkan bahwa model telah berhasil menyeimbangkan antara akurasi prediksi (*precision*) dengan daya jaring (*recall*), yang sangat penting dalam memitigasi risiko kredit pada layanan BNPL. Hasil evaluasi ini memberikan bukti bahwa integrasi data perilaku aplikasi mampu menghasilkan model skoring dengan tingkat keandalan (*reliability*) sebesar 70%, yang memungkinkan penyedia layanan BNPL untuk mengantisipasi potensi gagal bayar secara sistematis.

Setelah mengevaluasi performa model melalui metrik pada Tabel 3, dilakukan analisis lanjutan untuk mengidentifikasi variabel yang paling berpengaruh dalam proses pengambilan keputusan model *Random Forest*. Analisis *Feature Importance* ini krusial untuk memvalidasi apakah data perilaku digital benar-benar memberikan kontribusi signifikan dibandingkan data konvensional.



Gambar 5. Analisis Kontribusi Variabel terhadap Prediksi Risiko

Berdasarkan Gambar 5, terlihat bahwa *credit_score* dan *monthly_income* tetap menjadi indikator utama dalam prediksi risiko. Namun, temuan terpenting dalam penelitian ini adalah posisi variabel perilaku digital seperti *repayment_delay_days* dan *app_usage_frequency* yang menempati peringkat ketiga dan keempat.

Secara empiris, hal ini membuktikan bahwa:

- a. Signifikansi Data Alternatif: Variabel perilaku penggunaan aplikasi memiliki bobot kepentingan yang bersaing ketat dengan data keuangan tradisional. Hal ini mengonfirmasi bahwa jejak digital nasabah dapat menjadi cerminan tingkat kedisiplinan finansial.
- b. Prediktor Perilaku: Variabel *repayment_delay_days* memberikan informasi yang lebih tajam bagi model dibandingkan variabel demografis seperti lokasi (*location_enc*) atau status pekerjaan (*employment_enc*).
- c. Peran Cluster: Meskipun variabel Cluster berada pada posisi bawah, perannya tetap penting dalam memberikan konteks segmentasi awal yang membantu model *Random Forest* dalam memahami struktur data yang non-linear.

Temuan ini mendukung hasil pada Tabel 3; tingkat akurasi 70% tercapai berkat kombinasi antara data konvensional dan data alternatif. Hal ini memberikan implikasi kebijakan bagi penyedia layanan BNPL untuk mulai mengintegrasikan skor perilaku digital ke dalam sistem skoring kredit guna mendapatkan profil risiko yang lebih komprehensif.

Salah satu keunggulan dari penelitian terapan ini adalah ditemukannya variabel-variabel non-tradisional yang memiliki kontribusi signifikan terhadap risiko kredit di ekosistem BNPL, bersanding dengan indikator konvensional. Berdasarkan hasil analisis *Feature Importance*, variabel yang mendominasi prediksi adalah:

1. Credit Score & Monthly Income: Tetap menjadi pilar utama penilaian risiko, yang mengonfirmasi bahwa kapasitas finansial dasar masih merupakan faktor fundamental dalam ekosistem BNPL.
2. Repayment Delay Days: Menjadi prediktor ketiga terkuat. Hal ini menegaskan bahwa perilaku keterlambatan pembayaran dalam jangka pendek merupakan sinyal risiko yang sangat valid dalam skema Buy Now Pay Later.
3. App Usage Frequency: Variabel ini memberikan kontribusi yang lebih besar dibandingkan variabel demografis seperti usia atau lokasi. Temuan ini sangat menarik karena membuktikan secara empiris bahwa intensitas interaksi digital merupakan proksi efektif dari profil perilaku nasabah yang berkaitan dengan disiplin finansial."

Pembahasan krusial muncul ketika hasil *clustering* diintegrasikan ke dalam model prediksi. Fenomena False Negative sebanyak 456 data pada *Confusion Matrix* Gambar 4. mengonfirmasi bahwa pada nasabah berpendapatan tinggi yang terlambat membayar, model sering mengklasifikasikannya sebagai nasabah aman karena pengaruh *credit_score* yang tinggi, padahal secara perilaku mereka memiliki risiko. Hal ini memberikan implikasi kebijakan bahwa perusahaan Fintech tidak boleh hanya mengandalkan profil finansial (*wealth*), tetapi harus mengintegrasikan sistem peringatan berbasis perilaku (*behavioral nudges*) untuk segmen profesional ini guna menekan angka *repayment_delay_days*.

Berdasarkan temuan dari analisis segmentasi (K-Means) dan pemodelan prediksi (Random Forest), terdapat beberapa rekomendasi kebijakan yang relevan bagi penyelenggara *Fintech* maupun regulator:

a. Transformasi Skoring Kredit Tradisional ke *Dynamic Scoring*

Hasil penelitian membuktikan bahwa *credit_score* konvensional tidak lagi cukup untuk memitigasi risiko pada layanan BNPL. Regulator disarankan untuk mendorong penggunaan Alternative Credit Scoring (ACS) yang mengintegrasikan data perilaku digital (seperti *app_usage_frequency* dan *missed_payments* jangka pendek) guna melindungi konsumen dari jeratan utang (*over-indebtedness*).

b. Kebijakan Intervensi Berbasis Cluster (Targeted Intervention)

Penelitian ini merekomendasikan skema intervensi yang berbeda untuk tiap segmen:

1) Cluster 1 (The High-Risk Youth): Diperlukan regulasi yang mewajibkan batas maksimal (*credit limit*) yang lebih rendah dan edukasi literasi keuangan digital yang terintegrasi di dalam aplikasi.

2) Cluster 2 (The Affluent Late-Payers): Penekanan bukan pada pembatasan limit, melainkan pada Behavioral Nudges (seperti notifikasi otomatis yang lebih intensif atau denda progresif) untuk memperbaiki kedisiplinan pembayaran pada kelompok profesional berpendapatan tinggi.

c. Tata Kelola Data dan Perlindungan Konsumen

Mengingat tingginya pengaruh variabel *app_usage_frequency* terhadap prediksi risiko, terdapat urgensi dalam tata kelola privasi data. Kebijakan harus memastikan bahwa pengumpulan *digital trace* untuk keperluan skoring kredit dilakukan secara transparan dan sesuai dengan prinsip perlindungan data pribadi, guna menghindari diskriminasi algoritmik terhadap kelompok rentan.

d. Mitigasi Risiko Sistemik dalam Ekosistem Fintech

Melihat adanya korelasi antara rasio utang (*repayment_delay_days*) dengan kegagalan bayar di seluruh wilayah, regulator perlu mempertimbangkan pembentukan basis data terpusat (seperti SLIK di Indonesia) yang mencakup transaksi BNPL secara *real-time*. Hal ini krusial untuk mencegah fenomena nasabah yang melakukan pinjaman di beberapa platform secara bersamaan tanpa kontrol kapasitas pembayaran yang memadai.

KESIMPULAN

Berdasarkan hasil analisis, pengolahan data, dan pembahasan yang telah dilakukan pada bab sebelumnya mengenai risiko kredit pada layanan *Buy Now Pay Later* (BNPL), maka dapat ditarik beberapa simpulan sebagai berikut:

1. Karakteristik Nasabah dan Segmentasi: Implementasi algoritma *K-Means Clustering* berhasil mengidentifikasi tiga segmen nasabah yang berbeda secara signifikan, yaitu *The Safe Strategists* (risiko rendah, pendapatan stabil), *The High-Risk Youth* (risiko tinggi, pendapatan rendah), dan *The Affluent Late-Payers* (pendapatan tinggi namun abai terhadap tenggat waktu). Pemetaan ini didukung oleh analisis PCA yang mampu mempertahankan 74,70% varians data, membuktikan bahwa risiko gagal bayar tidak hanya berpusat pada faktor ekonomi, tetapi juga secara fundamental dipengaruhi oleh perilaku digital.
2. Efektivitas Pemodelan Prediktif: Penggunaan model *Random Forest Classifier* menunjukkan performa yang stabil dalam memprediksi kegagalan bayar

(*default_flag*) dengan tingkat akurasi mencapai 70%. Analisis *Feature Importance* menegaskan bahwa variabel perilaku seperti keterlambatan pembayaran (*repayment_delay_days*) dan frekuensi penggunaan aplikasi (*app_usage_frequency*) masuk dalam jajaran empat besar prediktor utama, mengungguli variabel demografis tradisional lainnya.

3. Akurasi dan Tantangan Klasifikasi: Melalui evaluasi *Confusion Matrix*, model terbukti memiliki kemampuan deteksi yang konsisten dengan nilai *Weighted Recall* sebesar 70%. Meskipun demikian, ditemukan fenomena *False Negative* sebanyak 456 data, yang mayoritas berasal dari kelompok nasabah berpendapatan tinggi namun memiliki disiplin pembayaran rendah. Hal ini menunjukkan bahwa penggunaan skor kredit konvensional saja tidak lagi cukup untuk memitigasi risiko pada layanan BNPL.
4. Dinamika Geospasial dan Implikasi Tata Kelola: Terdapat variasi risiko yang nyata antar wilayah geografis, di mana wilayah dengan regulasi keuangan yang lebih konservatif cenderung memiliki tingkat gagal bayar yang lebih rendah. Penelitian ini menyimpulkan bahwa penilaian risiko yang dinamis melalui integrasi *behavioral data* dapat membantu penyedia layanan Fintech menekan angka *Non-Performing Loan* (NPL) secara lebih objektif tanpa menghambat inklusi keuangan bagi kelompok masyarakat *unbanked*.

DAFTAR PUSTAKA

- Alman, T. (2022). *Node.js Design Patterns: Design and implement production-grade Node.js applications using proven patterns and techniques* (3rd ed.). Packt Publishing.
- Arner, D. W., Buckley, R. P., Zetsche, D. A., & Veidt, R. (2020). Sustainability, fintech and financial inclusion. *European Business Organization Law Review*, 21(1), 7–35. <https://doi.org/10.1007/s40804-020-00183-y>
- Bazarbash, M. (2019). *FinTech in financial inclusion: Machine learning applications in assessing credit risk*. International Monetary Fund (IMF) Working Papers.
- Dahl, R. (2018). *Original Node.js Presentation: The development of non-blocking I/O*. Joyent Inc.
- Di Maggio, M., Ratnadiwakara, D., & Carmichael, D. (2022). *Invisible primes: Fintech lending with alternative data*. National Bureau of Economic Research (NBER) Working Paper No. 29840. <https://doi.org/10.3386/w29840>
- Gerrans, P., Baur, D. G., & Lavagna-Slater, S. (2021). Buy now, pay later: A complement or substitute for credit cards? *Journal of Financial Counseling and Planning*, 32(3), 422–435. <https://doi.org/10.1891/JFCP-20-00045>
- Hand, D. J., & Henley, W. E. (1997). Statistical classification methods in consumer credit scoring: a review. *Journal of the Royal Statistical Society: Series A (Statistics in Society)*, 160(3), 523–541.
- Haverbeke, M. (2024). *Eloquent JavaScript: A Modern Introduction to Programming* (4th ed.). No Starch Press.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An introduction to statistical learning: With applications in R* (2nd ed.). Springer.
- Lanthaler, M., & Guetl, C. (2019). Model-driven development of scalable backend services using Node.js. *Journal of Web Engineering*, 18(1), 1–32.

- Otoritas Jasa Keuangan. (2022). *Peraturan Otoritas Jasa Keuangan Nomor 11/POJK.03/2022 tentang Penyelenggaraan Teknologi Informasi oleh Bank Umum*.
- Parsons, D., & MacCallum, K. (2021). Agile mentoring in online software engineering education: Lessons from national training programs. *Journal of Systems and Software*, 175, 110912. <https://doi.org/10.1016/j.jss.2021.110912>
- Thomas, L. C., Crook, J. N., & Edelman, D. B. (2017). *Credit scoring and its applications* (2nd ed.). Society for Industrial and Applied Mathematics (SIAM).