BAB II

KAJIAN PUSTAKA DAN HIPOTESIS PENELITIAN

A. Kajian Pustaka

1. Teori Risiko Kredit *(Credit Risk Theory)*

Teori risiko kredit dikemukakan oleh Robert C. Merton pada tahun 1974. Teori ini juga dikenal sebagai teori struktural. Teori risiko kredit berpendapat bahwa kejadian gagal bayar berasal dari perkembangan aset organisasi, yang dibentuk oleh proses infus dengan k parameter (Kabugu & G., 2022). Evolusi pemikiran sistematik mengenai evaluasi risiko kredit pertama kali muncul lewat karya Durand (1941), yang berupaya menciptakan mekanisme penilaian kredit yang objektif dengan memberikan bobot pada faktor risiko secara empiris (Çallı & Coşkun, 2021).

Salah satu elemen kunci dalam teori risiko kredit adalah model risiko kredit struktural yang diperkenalkan oleh Robert C. Merton (Nigmonov et al., 2024; Şahin, 2024). Teori ini berlandaskan pada teori penentuan harga opsi, di mana ekuitas perusahaan dianggap sebagai opsi beli *(call option)* terhadap aset perusahaan untuk mengevaluasi potensi gagal bayar berdasarkan fluktuasi nilai aset dan proporsi utang (Şahin, 2024). Edward Altman mulai menggunakan rasio keuangan dan analisis diskriminan melalui model *Z-Score* untuk memprediksi kebangkrutan perusahaan menggunakan statistik (Bennett et al., 2026).

Teori risiko kredit menjelaskan bahwa risiko kredit adalah kemungkinan terjadinya kerugian bagi pihak pemberi dana karena peminjam tidak mampu atau tidak mau memenuhi kewajiban pembayaran sesuai perjanjian. Risiko kredit diartikan sebagai kemungkinan kerugian yang dialami pemberi pinjaman akibat ketidakmampuan atau ketidakinginan peminjam untuk memenuhi kewajiban finansial yang telah disetujui sebelumnya (Avgeri & Psillaki, 2023).

Dalam konteks pinjaman, kerugian tersebut dapat muncul dalam bentuk pokok pinjaman yang tidak tertagih, bunga yang hilang, maupun biaya penagihan (Sifrain, 2023). Standar industri sering kali menetapkan ini sebagai keterlambatan pembayaran yang melebihi 90 atau 121 hari (Chen et al., 2021). Tunggakan *(delinquency)* menunjukkan keterlambatan dalam membayar angsuran (umumnya 30 hari atau lebih) yang menunjukkan indikasi awal masalah keuangan tetapi tidak selalu berujung pada kegagalan bayar total (Nigmonov et al., 2024)

Menurut teori ini, risiko kredit bergantung pada karakteristik peminjam (kemampuan bayar, niat, dan perilaku), karakteristik kontrak (suku bunga, tenor, dan limit pinjaman), serta kondisi eksternal seperti situasi ekonomi makro (Kabugu & G., 2022). Secara literatur, risiko kredit didefinisikan sebagai potensi kerugian yang timbul jika nasabah gagal memenuhi kewajiban finansialnya sesuai persyaratan yang disepakati.

Untuk melakukan penilaian kelayakan kredit yang komprehensif, teori ini mengandalkan beberapa komponen utama dalam mengevaluasi profil peminjam secara mendalam dengan metode analisis 6C (Chi, 2022):

1. *Character* (karakter): Menilai watak dan kemauan jujur debitur untuk membayar.
2. *Capacity* (kapasitas): Menilai kemampuan pembayaran kembali berdasarkan arus kas atau pendapatan.
3. *Capital* (modal): Kekayaan bersih atau ekuitas yang dimiliki debitur.
4. *Collateral* (jaminan): Kualitas aset yang diberikan sebagai agunan.
5. *Condition* (kondisi): Mempertimbangkan keadaan ekonomi makro dan tren pasar.
6. *Constraint* (batasan): Faktor tambahan yang mencakup hambatan regulasi atau kelangkaan sumber daya yang mempengaruhi pembayaran.

Risiko kredit dapat terjadi karena dipengaruhi oleh faktor yang terbagi menjadi beberapa kategori berdasarkan sumbernya (Akhmad et al., 2024; Chi, 2022; Nurfadilah et al., 2022; Sifrain, 2023).

1. Karakteristik Peminjam
   a) *Debt to Income Ratio (DTI)*: Rasio utang terhadap pendapatan adalah prediktor paling signifikan dalam menentukan risiko gagal bayar. Semakin tinggi *DTI*, semakin tinggi kemungkinan gagal bayar.

b) *Annual Income*: Pendapatan tahunan yang stabil berhubungan negatif dengan risiko gagal bayar; peminjam dengan pendapatan lebih tinggi cenderung lebih mampu membayar.

c) *Employment Length*: Lama bekerja mencerminkan stabilitas pendapatan. Peminjam yang bekerja lebih dari 10 tahun umumnya memiliki tingkat keberhasilan pembayaran yang lebih tinggi.

d) Tingkat Pendidikan: Pendidikan formal yang lebih tinggi secara signifikan terbukti menurunkan probabilitas gagal bayar.

2. Fitur dan Karakteristik Pinjaman

a) *Loan Amount* (Besar Pinjaman): Jumlah pinjaman yang besar meningkatkan beban pembayaran dan secara positif berkorelasi dengan probabilitas gagal bayar.

b) *Loan Duration* (Jangka Waktu): Pinjaman dengan durasi yang lebih lama dianggap lebih berisiko oleh pemberi pinjaman karena ketidakpastian masa depan.

c) *Loan Rate* (Suku Bunga): Suku bunga yang terlalu tinggi dapat membebani peminjam dan justru meningkatkan risiko kegagalan pembayaran.

3. Faktor Eksternal

a) Asimetri Informasi: Ketidaklengkapan data atau pemalsuan informasi oleh peminjam dalam *platform* digital meningkatkan profil risiko secara keseluruhan.

b) Faktor Makroekonomi: Variabel seperti inflasi, pertumbuhan PDB, dan tingkat suku bunga bank sentral (*Federal Funds Rate*) mempengaruhi kemampuan bayar dan selera risiko investor.

Adapun komponen utama dalam mengukur risiko kredit, diantaranya (Anh et al., 2021):

1. *Probability of Default (PD)***:** Peluang nasabah mengalami gagal bayar dalam periode waktu tertentu.
2. *Loss Given Default (LGD)***:** Estimasi besarnya kerugian yang akan diderita pemberi pinjaman jika terjadi gagal bayar, setelah memperhitungkan hasil pemulihan (*recoveries*).
3. *Expected Loss (EL):* Hasil perkalian antara PD, LGD, dan besarnya eksposur saat kegagalan terjadi

Teori Risiko Kredit *(Credit Risk Theory)* berfungsi sebagai payung besar yang mencakup variabel Suku Bunga (X2), Tenor Pinjaman (X3), dan Limit Pinjaman (X4) sebagai elemen dari karakteristik kontrak atau fitur pinjaman. Teori ini beranggapan bahwa risiko kerugian bagi pemberi pinjaman sangat ditentukan oleh karakteristik kontrak, di mana bunga yang terlalu tinggi, jangka waktu yang terlalu panjang, atau jumlah pinjaman yang terlalu besar dapat memperberat beban pembayaran dan ketidakpastian masa depan debitur (Kabugu & G., 2022). Di samping itu, teori ini juga mencakup variabel Riwayat Kredit (X5) karena kebiasaan keuangan sebelumnya dianggap sebagai indikator yang kuat untuk

meramalkan kinerja kredit di masa yang akan datang (Nigmonov et al., 2024).

2. Teori Informasi Asimetris *(Asymmetric Information Theory)*

Teori informasi asimetris dipelopori oleh George A. Akerlof pada tahun 1970. Sebagai pencetus awal, Akerlof berargumen bahwa dalam banyak pasar, pembeli cenderung menggunakan statistik rata-rata pasar untuk menilai kualitas suatu barang, sementara penjual memiliki pengetahuan spesifik yang lebih intim. Ketimpangan ini memberikan insentif bagi penjual untuk menawarkan barang dengan kualitas di bawah rata-rata pasar, yang pada akhirnya dapat memperkecil ukuran pasar tersebut (Kabugu & G., 2022).

Teori asimetri informasi dikembangkan oleh George Akerlof, Michael Spence, dan Joseph Stiglitz, yang kemudian menerima Nobel Ekonomi tahun 2001 karena berkontribusi dalam menjelaskan ketidakseimbangan informasi di pasar. Teori ini menyatakan bahwa dalam sebuah transaksi, satu pihak sering kali memiliki informasi yang lebih banyak dibandingkan pihak lainnya, yang dapat menyebabkan risiko dan kegagalan pasar (Outreach, 2026). George Akerlof menggunakan konsep *The Market for Lemons* untuk menunjukkan bahwa penjual memiliki pengetahuan yang lebih baik daripada pembeli, sementara Spence dan Stiglitz mengembangkan ide *signaling* dan *screening* guna mengatasi ketidakseimbangan informasi ini (Yan et al., 2015).

Dalam konteks kredit dan *P2P lending*, teori ini menyatakan bahwa peminjam umumnya lebih memahami keadaan keuangannya dibandingkan pemberi pinjaman, yang pada gilirannya meningkatkan risiko tidak dapat membayar (Akhmad et al., 2024). Menurut Auronen (2017) dalam penelitian (Kabugu & G., 2022), asimetri informasi menyebabkan pemberi pinjaman mustahil untuk membedakan secara pasti antara peminjam yang baik (*good borrowers*) dan peminjam yang buruk (*bad borrowers*). Dalam transaksi pinjaman, pemberi dana berada pada posisi yang tidak menguntungkan karena peminjam memegang hampir semua informasi yang dibutuhkan, sementara pemberi dana hanya bergantung pada informasi terbatas yang disediakan oleh *platform* (Mentink, 2022).

Masalah asimetri informasi dalam teori ini secara umum dibagi menjadi dua kategori utama berdasarkan waktu terjadinya, yaitu: (Akhmad et al., 2024; Kabugu & G., 2022; Mentink, 2022).

1. *Adverse Selection* (Seleksi Merugikan): Terjadi sebelum transaksi dilakukan (*ex-ante*). Hal ini muncul ketika pemberi pinjaman tidak dapat mengidentiksi profil risiko peminjam dengan benar, sehingga mereka mungkin secara tidak sengaja memberikan dana kepada peminjam berisiko tinggi yang seharusnya ditolak.
2. *Moral Hazard* (Bahaya Moral): Terjadi setelah transaksi dilakukan (*ex-post*). Peminjam mungkin mengambil tindakan yang tidak terduga atau terlalu berisiko yang merugikan pemberi dana, karena peminjam

tahu bahwa risiko kerugian finansial sepenuhnya ditanggung oleh investor

Tingkat asimetri informasi dalam suatu sistem dapat dipengaruhi dan dikurangi melalui beberapa faktor (Akhmad et al., 2024; Aliano et al., 2023; OJK-WP, 2018):

1. Mekanisme Tata Kelola *(Corporate Governance):* Komposisi dewan direksi yang mencakup direktur independen dan ahli keuangan terbukti dapat meningkatkan transparansi dan mengurangi perilaku manajerial yang opak.
2. Penggunaan Teknologi dan *Big Data*: Teknik analisis data yang efisien seperti *big data* dan kecerdasan buatan dapat membantu *platform* mengekstrak wawasan dari data non-tradisional untuk mengurangi celah informasi.
3. Informasi Lunak *(Soft Information)*: Penggunaan data seperti jejaring sosial, cara penulisan deskripsi pinjaman, hingga keterlibatan dalam komunitas dapat menjadi sinyal tambahan bagi investor untuk menilai karakter peminjam.
4. Peran Reputasi: Reputasi *platform* dan transparansi pelaporan data kredit yang terstandarisasi kepada otoritas (seperti OJK) sangat krusial untuk membangun kepercayaan dan mengurangi ketidakpastian informasi bagi investor

Teori ini mencakup variabel Riwayat Kredit (X5), Suku Bunga (X2), serta Limit Pinjaman (X4). Riwayat pinjaman dianggap sebagai "indikator"

krusial untuk mengurangi ketidakseimbangan informasi antara debitur dan *platform* (Mentink, 2022). Sementara itu, penentuan suku bunga yang terlalu tinggi bisa menyebabkan masalah seleksi merugikan (*adverse selection)*, dan limit pinjaman yang sangat besar dapat memunculkan risiko *moral hazard* setelah dana dicairkan (Akhmad et al., 2024; Kabugu & G., 2022).

3. Teori Perilaku Keuangan (*Behavioral Finance Theory*)

Kemunculan *Behavioral Finance Theory* dipelopori oleh Robert J. Shiller dan Richard H. Thaler. *Behavioral finance* adalah cabang dari studi keuangan yang mengeksplorasi bagaimana psikologi dan perilaku investor mempengaruhi keputusan keuangan (Sulistiyowati et al., 2023). Teori ini dikembangkan pada tahun 1970an sampai 1980an melalui penelitian oleh Daniel Kahneman dan Amos Tversky, dan kemudian diperluas oleh Robert J. Shiller. Keuangan perilaku menunjukkan bahwa investor tidak selalu bertindak secara rasional karena keputusan mereka dipengaruhi oleh emosi dan bias perilaku, seperti terlalu percaya diri dan kecenderungan untuk mengikuti kerumunan (Modoers, 2023).

Dalam penelitian Mentink (2022), perilaku keuangan didefinisikan sebagai upaya untuk mengintegrasikan wawasan perilaku ke dalam model keuangan guna menjelaskan bagaimana demografi dan sifat kepribadian memengaruhi keputusan pemberian pinjaman. Perilaku keuangan merupakan kemampuan individu dalam mengelola keuangan secara bijak dan tepat untuk menjaga kelangsungan hidup jangka pendek maupun

panjang (Elicia & Widjaja, 2020). Dalam penelitian Aliano et al. (2023), Huston (2010) menghubungkan perilaku keuangan dengan konsep literasi keuangan, di mana perilaku seperti *over-ogbeted* menunjukkan seberapa baik seseorang memahami risiko yang terlibat.

Berdasarkan buku *Behavior Financial Theory and Implementation* oleh Supriyanto (2021), beberapa ahli telah mendefinisikan perilaku keuangan, berikut adalah beberapa definisi perilaku keuangan :

a. Shefrin (2000), perilaku keuangan adalah studi yang mempelajari bagaimana fenomena psikologi mempengaruhi tingkah laku keuangannya. Tingkah laku dari para pemain saham tersebut disebut tingkah laku para praktisi.
b. Nofsinger (2001), perilaku keuangan yaitu mempelajari bagaimana manusia secara *actual* berperilaku dalam sebuah penentuan keuangan *(a financial setting).*
c. Litner (1998), perilaku keuangan merupakan suatu ilmu yang mempelajari bagaimana manusia menyikapi dan bereaksi atas informasi yang ada dalam upaya untuk mengambil keputusan yang dapat mengoptimalkan tingkat pengembalian dengan memperhatikan risiko yang melekat di dalamnya (unsur sikap dan tindakan merupakan faktor penentu dalam berinvestasi).
d. Fuller (2000), perilaku keuangan adalah penggabungan antara ekonomi klasik dan keuangan dengan psikologi dan ilmu pengambilan keputusan, dan perlu diketahui bahwa ilmu pengambilan keputusan

juga berkembang mengikuti perkembangan zaman, sehingga penerapan teori ekonomi klasik yang relatif bersifat baku, berbeda-beda seiring dengan perkembangan zaman.

Dari beberaapa definisi-definisi diatas, dapat ditarik kesimpulan bahwa perilaku keuangan merupakan bidang studi yang menggabungkan teori ekonomi tradisional dengan psikologi dan teori dalam pengambilan keputusan. Tujuannya adalah untuk memahami bagaimana elemen psikologis manusia berpengaruh pada cara mereka memandang, merespons, dan bertindak ketika menganalisis informasi keuangan serta melakukan keputusan investasi terbaik di tengah risiko yang ada.

Dalam penelitian Elicia (2020) dan Mentink (2022), beberapa faktor penting yang memengaruhi cara seseorang berperilaku dalam hal keuangan meliputi:

a. Karakteristik Demografis:
    1) Usia: individu dengan usia muda cenderung memiliki risiko yang lebih tinggi dan lebih akrab dengan teknologi dibandingkan individu yang sudah berusia lanjut.
    2) Jenis kelamin: pria biasanya lebih berani mengambil risiko, sedangkan wanita cenderung lebih hati-hati dalam membuat keputusan keuangan.
    3) Tingkat Pendidikan: tingkat pendidikan yang lebih tinggi berhubungan positif dengan tingkat literasi keuangan dan kemampuan seseorang dalam menganalisis risiko.

b. Karakteristik Psikologis:

1) Keterbukaan terhadap pengalaman adalah sifat kepribadian yang membuat seseorang lebih merasa nyaman dengan hal-hal yang tidak pasti dan lebih terbuka terhadap teknologi keuangan baru.

2) Kepercayaan adalah faktor utama yang mendorong investor untuk bergabung dan berpartisipasi dalam *platform* digital seperti *P2P Lending.*

c. Pengaruh Lingkungan Sosial:

1) Pengaruh orang tua: peran orang tua sebagai sarana utama dalam membentuk cara pikir dan kebiasaan mengelola uang sejak usia dini.

d. Faktor Finansial dan Pengalaman:

1) Tingkat Pendapatan (penghasilan): meskipun tidak selalu menunjukkan seberapa bijak seseorang, penghasilan memengaruhi kemampuan seseorang dalam menyisihkan uang untuk disimpan atau diinvestasikan.

2) Pengalaman Sebelumnya: Mempunyai pengalaman berinvestasi sebelumnya secara jelas membuat seseorang lebih tertarik untuk berinvestasi kembali.

Teori ini secara khusus dapat mencakup variabel Gender (X1). Dalam tinjauan pustaka dijelaskan bahwa karakteristik demografis, termasuk gender, memengaruhi perilaku dan pengambilan keputusan finansial seseorang. Secara teoretis, lelaki sering dihubungkan dengan sikap

yang lebih berani menjalani risiko, sedangkan perempuan biasanya lebih menghindari risiko dan lebih hati-hati, yang selanjutnya berpengaruh pada kemungkinan gagal bayar (Aliano et al., 2023). Teori ini juga membahas variabel Suku Bunga (X2) dengan konsep bias *overconfidence* dan variabel Tenor Pinjaman (X3) menggunakan konsep *present-bias.*

4. Risiko Gagal Bayar

a. Definisi

Risiko gagal bayar atau *default risk*, secara fundamental didefinisikan sebagai potensi kerugian finansial yang harus dihadapi oleh pemberi pinjaman akibat ketidakmampuan nasabah dalam memenuhi kewajiban utangnya sesuai dengan perjanjian awal (Çallı & Coşkun, 2021). Risiko gagal bayar adalah risiko yang muncul dari kombinasi faktor ketidakmampuan finansial atau kurangnya kemauan (*willingness*) dari pihak peminjam untuk melakukan pembayaran kembali sesuai jadwal (Avgeri & Psillaki, 2023). Dalam konteks industri keuangan modern, estimasi probabilitas gagal bayar menjadi instrumen krusial bagi manajemen risiko untuk menilai paparan kredit dan memitigasi potensi kerugian yang mungkin terjadi (Nigmonov et al., 2024).

Gagal bayar merupakan suatu kondisi ketika seorang peminjam melampaui batas waktu keterlambatan tertentu, yang biasanya berkisar antara 90 hingga 121 hari (Xu et al., 2021). Gagal bayar

merupakan risiko yang timbul akibat ketidakmampuan peminjam dalam memenuhi kewajiban pembayaran pinjaman sesuai dengan perjanjian (Chen et al., 2021). Gagal bayar merujuk pada situasi di mana peminjam tidak bisa membayar cicilan atau utang pokok serta bunganya tepat waktu sesuai dengan kesepakatan yang telah dibuat (Şahin, 2024)

b. Jenis – jenis risiko gagal bayar

Berdasarkan penelitian Ayuningtyas (2020), jenis-jenis risiko gagal bayar meliputi:

1) Risiko gagal bayar, adalah risiko yang muncul ketika peminjam tidak bisa memenuhi kewajibannya untuk mengembalikan pinjaman sesuai perjanjian yang telah disepakati. Peminjam tidak dapat melakukan pembayaran pinjaman tepat waktu.
2) Risiko reputasi bagi perusahaan fintech, risiko ini timbul karena berbagai faktor seperti kegagalan layanan, masalah regulasi, atau skandal yang bisa memengaruhi citra perusahaan. Jika banyak peminjam gagal membayar, maka reputasi perusahaan akan rusak. Hal ini dapat melemahkan kepercayaan calon peminjam.
3) Risiko finansial yang muncul apabila terjadi gagal bayar, perusahaan *fintech* tidak akan dapat menerima pinjaman termasuk bunga dan margin yang seharusnya diterima

4) Risiko hukum yang muncul jika terjadi pelanggaran kontrak yang tidak dapat dipenuhi, Apabila terjadi wanprestasi yang tidak dapat diselesaikan secara damai perusahaan fintech terancam tindakan hukum oleh pemberi pinjamannya.

Menurut Rohimah (2023), jenis – jenis risiko gagal bayar yaitu:

1) Risiko kredit, dimana peminjam mengalami keterlambatan pembayaran melalui *platform* pinjaman online dengan alasan tertentu.
2) Riwayat kredit, jika peminjam dapat mengelola keuangannya dengan baik maka risiko gagal bayar dapat dihindari dan apabila peminjam tidak dapat mengelola keuanganya dengan baik maka akan mengalami risiko gagal bayar.

c. Faktor- faktor risiko gagal bayar

Dalam penelitian Oktapriana et al. (2023), gagal bayar dapat dipengaruhi oleh beberapa faktor, diantaranya yaitu:

1) Rendahnya literasi keuangan atau kredit online. Perhitungan bunga, tanggal jatuh tempo pembayaran dan akibat keterlambatan pembayaran, maka semakin besar pula risiko gagal bayar.
2) Rendahnya latar belakang pendidikan, individu dengan tingkat pendidikan yang lebih rendah maka akan memiliki pengetahuan keuangan yang lebih rendah dibandingkan tingkat pendidikan

yang lebih tinggi. Hal ini dapat meningkatkan risiko gagal bayar.

3) Besarnya kebutuhan dana. Apabila kebutuhan semakin besar maka akan mendorong adanya pengajuan kredit dan semakin besar tekanan ekonomi untuk membayar cicilan yang berpotensi menimbulkan gagal bayar.
4) Kurang teliti dalam menganalisis kemampuan membayar. Mudahnya persetujuan kredit online dapat menyebabkan kurang telitinya calon debitur menganalisis kemampuannya membayar cicilan sehingga berisiko gagal bayar.
5) Lemahnya pengawasan dan sanksi dari pemberi kredit

Faktor faktor yang berpengaruh signifikan pada risiko gagal bayar diungkapkan dalam penelitian yang dilakukan oleh Hadiantini & Nike (2022) yang meliputi:

1) Karakteristik Demografi & Sosial Ekonomi
   a) Pendapatan: merupakan faktor paling krusial. Kemungkinan gagal bayar lebih tinggi jika pendapatan debitur lebih rendah atau tidak pasti.
   b) Pekerjaan: jenis pekerjaan menentukan stabilitas arus kas. Debitur yang bekerja di sektor informal cenderung memiliki risiko lebih tinggi daripada debitur yang bekerja di sektor formal.

c) Jumlah tanggungan: pengeluaran rumah tangga yang lebih besar dapat mengubah prioritas pembayaran cicilan karena jumlah anggota keluarga yang ditanggung.

d) *Track Record*: Perilaku pembayaran di masa lalu menjadi indikator kuat. Debitur yang pernah terlambat bayar sebelumnya cenderung mengulangi pola yang sama.

2) Karakteristik Pinjaman

a) Besar Pinjaman (*Plafon*): Bunga dan pokok lebih tinggi jika pinjaman terlalu besar dan tidak proporsional dengan penghasilan.

b) Tenor (Jangka Waktu): Ketidakpastian risiko di masa depan meningkat dengan masa pinjaman yang terlalu panjang.

c) Tujuan Penggunaan Dana: Kredit yang digunakan untuk konsumtif memiliki risiko gagal bayar lebih tinggi dibandingkan kredit produktif (modal usaha).

d. Indikator gagal bayar

Dalam konteks layanan pendanaan bersama berbasis teknologi (LPBBTI) di Indonesia, indikator utama yang digunakan adalah (Novellita, 2025):

1) TKB90 (Tingkat Keberhasilan 90 hari): ukuran tingkat keberhasilan penyelenggara *Fintech P2P Lending* dalam menfasilitasi penyelesaian kewajiban pinjam meminjam dalam jangka waktu sampai dengan 90 hari terhitung sejak jatuh

tempo. TKB90 ini merupakan rasio dari penyelenggara *P2P Lending* tersebut semakin tinggi persentase TKB90 yang tertera, maka semakin baik pula penyelenggaraan pinjam meminjam yang dilaksanakan oleh Penyelenggara *Fintech P2P Lending* tersebut.

2) TWP90 (Tingkat Wanprestasi 90 hari): Ukuran tingkat wanprestasi atau kelalaian penyelesaian kewajiban yang telah melewati batas waktu di atas 90 hari sejak tanggal jatuh tempo. Indikator ini sering dianggap setara dengan *Non-Performing Loan* (NPL) pada perbankan konvensional.

5. Gender

Gender dalam bidang keuangan tidak hanya merupakan perbedaan biologis antara pria dan wanita, tetapi juga merupakan sebuah konstruksi sosial dan budaya yang mencakup peran, sikap, cara berpikir, serta harapan yang dimiliki individu berdasarkan konteks sosial mereka (Fahsaniah et al., 2025). Ciri-ciri ini mencakup sifat-sifat yang terpengaruh oleh budaya, lingkungan, nilai-nilai hidup, serta perilaku psikologis yang berbeda saat mengambil keputusan (Pasek, 2022). Dalam praktiknya, gender sering digunakan sebagai indikator untuk memahami sejauh mana kepercayaan diri yang berlebihan *(overconfidence)* dan kecenderungan individu terhadap risiko dalam pengelolaan finansial (Maulia & Yohanna, 2023). Dengan begitu, perbedaan gender menunjukkan variasi dalam cara pria

dan wanita memandang tanggung jawab serta hak mereka di masyarakat dan institusi (Aliano et al., 2023).

Pengaruh antara jenis kelamin dan kemungkinan terjadinya gagal bayar menunjukkan hasil yang bervariasi, tetapi cenderung menunjukkan bahwa perempuan memiliki tingkat risiko yang lebih rendah (Pas, 2025). Banyak penelitian di bidang pinjaman *peer to peer (P2P)* menunjukkan bahwa perempuan sebagai peminjam biasanya memiliki peluang untuk gagal bayar yang lebih kecil dan performa pengembalian yang lebih baik dibandingkan dengan laki-laki (Aliano et al., 2023). Data menunjukkan bahwa laki-laki memiliki risiko gagal bayar yang 1,5 kali lebih tinggi setiap bulan selama periode pinjaman dibandingkan dengan perempuan (Shen et al., 2022). Namun, ada juga penelitian lain yang menunjukkan bahwa dampak gender dapat menjadi tidak signifikan atau bahkan berlawanan di *platform* atau daerah tertentu, yang menunjukkan adanya keanekaragaman di antara peminjam (Fahsaniah et al., 2025).

Hubungan antara gender dan tingkat risiko diuraikan melalui teori keuangan perilaku *(finance behavior)*, khususnya terkait dengan konsep penghindaran risiko dan bias psikologis (Maulia & Yohanna, 2023). Pria sering kali diasosiasikan dengan sikap yang lebih berani dalam mengambil risiko, penggunaan logika yang lebih mendominasi, serta tingkat kepercayaan diri yang lebih tinggi, yang secara teori dapat menyebabkan pengambilan utang di luar batas kemampuan mereka. Sementara itu, wanita secara empiris cenderung lebih menghindari risiko, bersikap lebih

berhati-hati, dan biasanya melakukan analisis lebih mendalam sebelum melakukan transaksi keuangan (Bátiz-zuk & González-holden, 2023). Teori ini menegaskan bahwa tindakan keuangan seseorang tidak hanya dipengaruhi oleh logika yang jelas, tetapi juga sangat dipengaruhi oleh faktor emosional dan perbedaan pola pikir antar jenis kelamin dalam pengelolaan sumber daya (Febrianty et al., 2024).

6. Suku Bunga

a. Definisi suku bunga

Suku bunga adalah harga atau biaya yang dibebankan oleh *platform P2P lending* kepada peminjam untuk menggunakan dana dalam jangka waktu tertentu yang digunakan sebagai kompensasi bagi investor atas risiko gagal bayar dan nilai waktu uang (Benavides-Franco et al., 2023). Suku bunga merupakan biaya yang dibayar peminjam sebagai imbalan atas penggunaan dana pinjaman, biasanya dinyatakan dalam persentase dari pokok pinjaman (Christopher, 2025)

Platform P2P sering kali mampu menawarkan suku bunga yang lebih kompetitif dibandingkan lembaga keuangan tradisional karena biaya operasional yang lebih rendah, meskipun dalam praktiknya suku bunga *P2P* bisa lebih tinggi karena mencerminkan persepsi risiko pemberi pinjaman terhadap nasabah yang tidak terjangkau oleh bank konvensional (Vu, 2023). Dalam praktiknya, tingkat suku bunga ini biasanya ditetapkan secara eksplisit oleh *platform* melalui analisis menyeluruh terhadap karakteristik

peminjam untuk menyeimbangkan permintaan pinjaman dengan dana yang tersedia (Lee, 2020).

Dalam teori risiko kredit, suku bunga dipandang sebagai mekanisme *risk-based pricing*, di mana premi risiko yang lebih tinggi dibebankan kepada nasabah dengan probabilitas gagal bayar yang lebih besar guna menutupi estimasi kerugian (Rau & Shuaib, 2022; Şahin, 2024). Melalui teori informasi asimetris, suku bunga yang terlalu tinggi dapat memicu *adverse selection*, di mana peminjam berkualitas baik justru menarik diri dari pasar, sementara peminjam berisiko tinggi tetap bertahan karena memang tidak memiliki niat tulus untuk membayar (Avgeri & Psillaki, 2023; Nigmonov et al., 2024).

Selain itu, teori perilaku keuangan menjelaskan adanya bias *overconfidence*, di mana peminjam sering kali terlalu optimis terhadap pendapatan masa depannya sehingga berani mengambil beban bunga tinggi yang berujung pada kegagalan pembayaran (Maulia & Yohanna, 2023). Implementasi dari kerangka teori tersebut kemudian dioperasionalkan oleh *platform P2P* melalui sejumlah metrik kuantitatif yang menjadi tolok ukur praktis bagi investor dalam menilai risiko (Pas, 2025)

b. Indikator suku bunga *P2P Lending*

Berdasarkan literatur, variabel suku bunga dalam model penelitian biasanya diukur melalui indikator-indikator berikut (OJK-WP, 2018; Sifrain, 2023; Vu, 2023):

1) *Lending Rate / Annual Percentage Rate (APR):* Tingkat suku bunga tahunan yang secara eksplisit tertulis dalam kontrak.
2) Suku Bunga Harian: Khusus di Indonesia, indikator ini mencakup biaya layanan harian yang dibatasi oleh regulasi.
3) Biaya Layanan dan Administrasi *(Platform Fee):* Biaya tambahan yang dipotong di awal atau ditambahkan ke dalam total beban bunga.
4) Akumulasi Denda Keterlambatan: Biaya penalti yang dihitung per hari setelah jatuh tempo, yang dapat meningkatkan total utang secara signifikan.
5) *Loan Grade/Rating*: Peringkat risiko yang diberikan *platform* yang berfungsi sebagai indikator kategoris bagi tingkat bunga yang akan diterima nasabah

7. Tenor pinjaman

a. Definisi

Tenor pinjaman pada dasarnya diartikan sebagai periode atau durasi yang disepakati dalam kontrak antara peminjam dan kreditur untuk menyelesaikan semua kewajiban utang beserta bunganya, yang ditetapkan di awal perjanjian (OJK-WP, 2018). Dalam pinjaman *P2P*,

tenor adalah faktor penting yang mempengaruhi jumlah pembayaran yang harus dilakukan serta besaran cicilan yang perlu dilunasi oleh debitur di setiap periode (Monje et al., 2025). Faktor ini biasanya digunakan oleh *platform* untuk mengelompokkan jenis produk pinjaman, mulai dari jangka waktu pendek sampai panjang, yang bisa mencapai 60 bulan (Snakkers, 2021).

Secara fungsional, lama tenor menggambarkan sejauh mana risiko yang dihadapi oleh investor selama periode tertentu, di mana jangka waktu pelunasan yang lebih panjang biasanya berhubungan dengan tingkat ketidakpastian yang lebih besar mengenai situasi keuangan peminjam di masa yang akan datang (Vu, 2023). Penetapan panjang waktu ini menjadi alat dalam manajemen risiko yang dimanfaatkan oleh *platform* untuk mengevaluasi kemampuan bayar dari klien dan mengurangi kemungkinan kerugian (Pas, 2025). Peminjam sering kali memilih jangka waktu tertentu agar kewajiban pembayaran bulanan mereka selaras dengan kestabilan aliran kas, sehingga dapat menghindari gagal bayar akibat fluktuasi pendapatan yang tiba-tiba (Rau & Shuaib, 2022).

Variabel tenor atau jangka waktu pinjaman dalam teori risiko kredit mencerminkan lama paparan risiko, di mana semakin lama periode pinjaman, semakin meningkat ketidakpastian terkait kondisi ekonomi peminjam, yang berhubungan dengan meningkatnya kemungkinan gagal bayar (Astuti et al., 2022; Suteja, 2025). Dalam

teori perilaku keuangan, hal ini dijelaskan melalui konsep *present-bias*, di mana individu cenderung melebih-lebihkan kemampuan mereka untuk memenuhi kewajiban di masa depan, sehingga bersedia mengambil tenor yang lebih panjang tanpa perencanaan yang matang (Johnston, 2020).

Sebaliknya, menurut teori perilaku yang diajukan oleh Dan Ariely, tenggat waktu atau tenor yang lebih pendek dianggap lebih efektif karena memaksa individu untuk menyusun rencana aksi dan mempertahankan tanggung jawab atas utang mereka (Johnston, 2020). Pengaturan durasi pinjaman yang tidak fleksibel dalam sistem digital juga dipandang dapat membahayakan stabilitas keuangan nasabah jika beban angsuran tidak disesuaikan secara tepat dengan arus kas masuk mereka (Suteja, 2025).

b. Indikator tenor pinjaman *P2P lending*

Berdasarkan penelitian (Avgeri & Psillaki, 2023), tenor pinjaman memiliki beberapa indikator, yaitu:

1) *Term/Duration*: Pilihan periode tetap yang ditawarkan di *platform*, yang biasanya diukur dalam jumlah bulan seperti 36 atau 60 bulan.
2) *Loan Maturity*: Tanggal atau waktu akhir di mana seluruh jumlah utama dan bunga harus dibayar lunas sepenuhnya.

3) *Repayment Frequency*: Rencana pembayaran cicilan yang telah ditetapkan, seperti bulanan, mingguan, atau pembayaran sekali di akhir periode.
4) *Survival Time*: Ukuran waktu yang menunjukkan jumlah hari atau bulan sejak pinjaman diberikan hingga terjadinya gagal bayar atau pelunasan

8. Limit pinjaman

a. Definisi

Limit pinjaman adalah jumlah total uang yang disetujui oleh *platform* untuk diberikan kepada peminjam berdasarkan permohonan awal serta hasil evaluasi kelayakan kredit (Avgeri & Psillaki, 2023; Snakkers, 2021). Jumlah limit ini menunjukkan nilai risiko secara nominal untuk investor, di mana angka yang lebih besar secara langsung menambah kewajiban finansial yang harus dipenuhi oleh peminjam (Vu, 2023). Dalam sektor *P2P lending*, limit pinjaman sangat bervariasi, mulai dari dana kecil untuk keperluan konsumsi hingga batas maksimum yang diatur dengan ketat oleh lembaga keuangan nasional (Andrianto & Nurjanah, 2023).

Secara fungsional, batas pinjaman adalah elemen penting dalam proses penilaian kredit yang dilakukan oleh algoritma *platform* untuk menyeimbangkan kebutuhan modal peminjam dengan keamanan dana investor (Sifrain, 2023). Penggunaan batas ini sering kali berkaitan dengan tingkat ketergantungan peminjam pada utang eksternal, di

mana penggunaan batas yang berlebihan dapat menunjukkan adanya tekanan keuangan (Aleksandrova, 2021). Penilaian yang akurat terhadap batas pinjaman sangat krusial bagi *platform* untuk menciptakan portofolio yang sehat dan mengurangi risiko kerugian akibat pinjaman berlebih (Cecchi et al., 2021; Xu, 2025).

Dalam konteks teori risiko kredit, batasan pinjaman yang besar selalu menunjukkan peningkatan kemungkinan terjadinya gagal bayar karena tingginya beban pengembalian dibandingkan dengan kemampuan pendapatan peminjam (Lee, 2020; Nigmonov et al., 2024; Sifrain, 2023). Secara statistik, setiap tambahan satu unit pinjaman terbukti meningkatkan kemungkinan pinjaman tersebut menjadi bermasalah akibat bertambahnya tekanan terhadap likuiditas debitur (Xu, 2025). Di sisi lain, pinjaman dengan jumlah yang lebih rendah biasanya menunjukkan tingkat pengembalian yang lebih baik karena beban utang lebih mudah diatur oleh individu atau usaha kecil (Anh et al., 2021).

Melalui sudut pandang teori informasi asimetris, jumlah pinjaman yang tinggi dapat menimbulkan isu *moral hazard*, di mana peminjam cenderung lebih mementingkan kepentingan pribadi dibandingkan kepentingan para investor setelah dana dicairkan (Vu, 2023). Untuk mengatasi masalah ini, *platform* memanfaatkan sistem peringkat kredit untuk menyampaikan informasi mengenai kredibilitas peminjam kepada investor agar mereka dapat menilai

apakah jumlah yang diminta sesuai dengan profil risiko yang ada (Avgeri & Psillaki, 2023). Di samping itu, ada praktik progressive lending yang mana *platform* mulai memberikan limit kecil sebagai alat seleksi untuk mengurangi adverse selection sebelum memberikan akses kepada dana yang lebih besar di masa mendatang(Cecchi et al., 2021).

b. Indikator limit pinjaman *P2P Lending*

Berdasarkan penelitian (Vu, 2023), limit pinjaman memiliki beberapa indikator, yaitu:

1) *Applied Amount*: besaran dana yang diajukan oleh peminjam sebelum melewati tahap validasi dan persetujuan dari *platform*.
2) *Funded Amount*: total jumlah pinjaman yang telah disetujui dan berhasil diperoleh peminjam melalui *platform* daring.
3) *Loan Size*: klasifikasi besar pinjaman (contohnya dalam ribuan unit mata uang) untuk menganalisis variasi risiko di antara segmen nasabah yang berbeda..
4) *Debt-to-Income (DTI) Ratio*: perbandingan total utang dengan pendapatan bulanan untuk menilai batas aman dari limit yang diberikan

9. Riwayat kredit

a. Definisi

Riwayat kredit secara dasar diartikan sebagai catatan tentang perilaku pembayaran di masa lalu yang digunakan untuk menilai

apakah peminjam mampu dan mau memenuhi kewajiban keuangannya di masa mendatang (Snakkers, 2021). Data ini mencakup ringkasan keadaan finansial pengguna, pemanfaatan jalur kredit yang ada, serta informasi terkait aspek pribadi seperti rekam jejak pembayaran dan variasi pendapatan(Snakkers, 2021). Dalam sektor keuangan, riwayat kredit menjadi faktor utama dalam menilai kelayakan kredit karena memberikan data objektif yang menggambarkan profil risiko individu dari waktu ke waktu (Lee, 2020).

Dalam dunia *platform* peminjaman *P2P*, riwayat kredit dianggap sebagai alat untuk mengumpulkan informasi tentang peminjam dari berbagai sumber, termasuk bank dan lembaga pemeringkat kredit, untuk memperkirakan kemungkinan terjadinya gagal bayar (Vu, 2023; Xu, 2025). Rekam ini berisi catatan pinjaman yang telah diambil sebelumnya, baik yang berjalan dengan lancar maupun yang mengalami masalah, serta pengalaman dalam mengelola berbagai jenis cicilan (Kovrijnykh et al., 2023). Penilaian terhadap rekam jejak pembayaran ini memungkinkan *platform* dan investor untuk membedakan antara pengguna yang patuh dan mereka yang berisiko tinggi dalam perilakunya (Bennett et al., 2026; Muñoz-Cancino et al., 2022).

Ditinjau dari perspektif teori asimetri informasi, riwayat kredit berfungsi sebagai sinyal penting yang membantu mengurangi

ketidakseimbangan informasi antara pihak peminjam dan investor (Vu, 2023). Peminjam yang memiliki rekam jejak pembayaran yang baik memberikan tanda yang dapat dipercaya tentang kualitas kredit mereka, sehingga membantu investor mengurangi masalah pemilihan buruk sebelum dana diberikan (Çallı & Coşkun, 2021). Peminjam yang kembali *(repeat borrowers)* dengan riwayat positif di *platform* secara signifikan mengurangi ketidakpastian informasi karena *platform* sudah menjalani proses penyaringan dan pengawasan dari transaksi sebelumnya (Lee, 2020; Vu, 2023).

Menurut teori risiko kredit, riwayat kredit adalah komponen utama dalam model penilaian kredit untuk memperkirakan secara tepat kemungkinan gagal bayar (Nigmonov et al., 2024). Model-model tradisional seperti *Altman Z-Score* atau model struktural *Merton* berasumsi bahwa perilaku finansial di masa lalu adalah indikator yang kuat untuk kinerja kredit di masa depan (Bennett et al., 2026). Dengan menggunakan data masa lalu ini, *platform* dapat menerapkan mekanisme penetapan harga berdasarkan risiko, di mana nasabah dengan riwayat kredit yang buruk akan dikenakan biaya risiko yang lebih tinggi untuk menutupi kemungkinan kerugian yang mungkin terjadi (Kovrijnykh et al., 2023).

b. Indikator riwayat kredit *P2P lending*

Di Indonesia, seluruh data riwayat kredit ini terekam dalam sistem SLIK (Sistem Layanan Informasi Keuangan) yang dikelola

oleh Otoritas Jasa Keuangan (A. Yusuf et al., 2025). Status kolektibilitas nasabah dibagi ke dalam beberapa kategori utama (OJK, 2025a):

1) Lancar: Nasabah yang memenuhi kewajiban tepat waktu.
2) Dalam Perhatian Khusus (DPK): terdapat indikasi keterlambatan ringan namun belum masuk kategori macet. Indikasi keterlambatan 11 sampai 30 hari.
3) Kurang lancar: terjadi keterlambatan pembayaran selama 31 sampai 60 hari setelah jatuh tempo.
4) Diragukan: terjadi keterlambatan pembayaran selama 61 sampai 90 hari setelah jatuh tempo.
5) Macet: terjadi keterlambatan lebih dari 90 hari.

Dalam penelitian yang dilakukan oleh Aleksandrova (2021), riwayat kredit dikategorikan dengan melihat waktu penggunaan fasilitas kredit dan jumlah akun yang dimiliki oleh nasabah untuk mengevaluasi kematangan profil kredit mereka. Indikator yang digunakan meliputi variabel waktu dan jumlah akun sebagai berikut:

1) Kematangan Akun: Diukur berdasarkan berapa lama sudah berjalan sejak kredit pertama kali dibuka dan usia akun cicilan bank yang paling lama.
2) Kapasitas Akun: Mencakup jumlah lini kredit yang saat ini aktif dalam catatan kredit peminjam serta total seluruh lini kredit yang pernah dimiliki.

3) Aktivitas *Revolving*: Meliputi durasi sejak dibukanya akun kredit bergulir *(revolving)* yang paling tua

10. *Machine Learning*

Machine Learning (ML) adalah salah satu cabang dari kecerdasan buatan *(Artificial Intelligence)* yang menitikberatkan pada pengembangan algoritma dan model agar sistem komputer dapat belajar dari data secara otomatis (Ichsan, 2025). Dalam buku Arifuddin et al. (2024), definisi klasik yang diusulkan oleh Tom M. Mitchell mengemukakan bahwa suatu program komputer bisa dianggap belajar dari pengalaman (E) dalam konteks tugas (T) dan ukuran kinerja (P), jika kinerjanya pada tugas tersebut meningkat seiring dengan bertambahnya pengalaman. Di masa transformasi digital saat ini, ML menjadi alat penting untuk mengambil pengetahuan dari kumpulan data besar dan kompleks guna menghasilkan prediksi atau keputusan otomatis tanpa perlu diprogram secara khusus untuk setiap tugas tertentu (Arifuddin et al., 2024).

Proses implementasi *machine learning* terdiri dari beberapa langkah sistematis yang dimulai dengan pengumpulan data relevan dari berbagai sumber. Secara umum, cara kerja *machine learning* melibatkan beberapa tahapan utama berikut (Arifuddin et al., 2024; Goodfellow et al., 2016; Russell & Norvig, 2022)

a. Pengumpulan Data *(Data Collection)*

Proses ini dimulai dengan mengumpulkan data yang relevan, baik dari sumber internal (seperti data transaksi perusahaan) maupun sumber

eksternal (seperti data dari sensor atau data publik). Kualitas dan jumlah data yang digunakan sangat memengaruhi performa model *Machine Learning.*

b. Praproses Data *(Data Preprocessing)*

Data mentah umumnya tidak dapat digunakan secara langsung untuk melatih model *Machine Learning*. Tahapan ini mencakup pembersihan data (*data cleaning*), pengelolaan data yang hilang (*missing values*), normalisasi atau standarisasi data, serta transformasi data agar sesuai dengan kebutuhan algoritma yang akan diterapkan.

c. Pemilihan dan Pembuatan Model *(Model Selection and Building)*

Pada tahap ini, algoritma *Machine Learning* yang tepat dipilih berdasarkan jenis masalah yang ingin diselesaikan, seperti klasifikasi, regresi, *clustering*, dan sebagainya. Model kemudian dibangun dan dilatih menggunakan data pelatihan.

d. Pelatihan Model *(Model Training)*

Model dilatih dengan data yang telah disiapkan. Tujuan dari pelatihan ini adalah agar model dapat memahami pola dari data, serta meminimalkan tingkat kesalahan melalui optimasi fungsi kehilangan. Proses ini umumnya melibatkan teknik optimasi seperti *gradient descent.*

e. Evaluasi Model *(Model Evaluation)*

Setelah proses pelatihan selesai, kinerja model dievaluasi dengan menggunakan data uji yang belum pernah dikenali oleh model

sebelumnya. Metode evaluasi yang biasa digunakan mencakup metrik seperti akurasi, presisi, *recall,* dan *F1-score* untuk klasifikasi, serta *Mean Squared Error (MSE)* untuk regresi.

Dalam praktiknya, *Machine Learning* terbagi menjadi tiga kategori utama berdasarkan metode pembelajarannya, yaitu *Supervised Learning, Unsupervised Learning,* dan *Reinforcement Learning* (Arifuddin et al., 2024; Quinlan, 1988).

a. *Reinforcement Learning*

Reinforcement Learning (RL) merupakan pendekatan dalam *Machine Learning* di mana sebuah agen belajar melalui interaksi langsung dengan lingkungan. Agen melakukan tindakan, menerima umpan balik berupa hadiah atau hukuman, dan kemudian memanfaatkan informasi tersebut untuk memperbaiki tindakannya di masa mendatang.

Reinforcement Learning umumnya diterapkan dalam masalah yang melibatkan pengambilan keputusan bertahap, di mana tindakan saat ini berpengaruh terhadap hasil di masa mendatang. Sasaran utama dari *Reinforcement Learning* adalah untuk memaksimalkan total hadiah dalam jangka waktu yang panjang. Contoh penggunaan *Reinforcement Learning* meliputi:

1) Pengendalian robot otonom.
2) Permainan video game atau catur (misalnya *AlphaGo*).

3) Sistem rekomendasi yang dapat beradaptasi dengan umpan balik dari pengguna.

b. *Unsupervised Learning*

Unsupervised Learning atau pembelajaran tanpa pengawasan menggunakan data yang tidak mempunyai label. Tujuan utama metode ini adalah untuk menemukan pola tersembunyi, struktur, atau hubungan dalam data tanpa adanya arahan jawaban yang telah ditentukan. Model Pembelajaran Tanpa Pengawasan sering diterapkan untuk:

1) *Clustering*: Mengelompokkan data berdasarkan kesamaan, contohnya segmentasi pelanggan dalam pemasaran.
2) *Association Rule Learning*: Mencari hubungan asosiasi antara barang, seperti yang diterapkan dalam sistem rekomendasi produk di *e-commerce*

c. *Supervised Learning*

Supervised Learning atau pembelajaran terawasi adalah tipe pembelajaran mesin di mana model dilatih menggunakan kumpulan data yang sudah memiliki label. Dengan kata lain, untuk setiap data masukan (*input*), tersedia jawaban atau sasaran (*output*) yang benar. Model belajar dengan memetakan *input* ke *output* berdasarkan pola dari data yang diberikan. Prinsip kerja model ini mirip dengan proses belajar menggunakan contoh soal dan kunci jawaban. Model terus diperbaiki selama pelatihan agar prediksi

yang dihasilkan semakin mendekati nilai yang sebenarnya. Penggunaan *Supervised Learning* dapat dilihat dalam beberapa contoh berikut:

1) Regresi: Memprediksi nilai yang bersifat kontinu, seperti dalam memperkirakan harga rumah berdasarkan ukuran dan lokasi yang dimiliki.
2) Klasifikasi: Mengelompokkan data ke dalam kategori tertentu, seperti dalam proses mendeteksi apakah sebuah email merupakan spam atau bukan spam.

Algoritma klasifikasi merupakan komponen penting dari pembelajaran terawasi dalam struktur *machine learning*. Tujuan klasifikasi adalah untuk mengembangkan model yang mampu memprediksi label kategori atau kelas diskrit dari suatu data dengan mempertimbangkan fitur-fitur yang ada. Berikut ini adalah taksonomi dan penjelasan mengenai metode-metode klasifikasi utama (Arifuddin et al., 2024):

a) Naive Bayes

Naive Bayes adalah algoritma klasifikasi yang berbasis pada probabilitas dan menggunakan *Teorema Bayes* dengan asumsi "*naif*" bahwa setiap fitur dalam dataset bersifat independen satu sama lain secara bersyarat (Russell & Norvig, 2022). Dasar matematika dari algoritma ini berfungsi untuk menghitung probabilitas *posterior*, yaitu kemungkinan sebuah

contoh termasuk dalam kelas tertentu berdasarkan bukti atau fitur yang terlihat. Secara resmi, kelas yang diprediksi ditentukan dengan mencari nilai maksimum dari hasil perkalian antara probabilitas awal kelas dan probabilitas kemungkinan dari setiap fitur yang ada. Meskipun asumsi independensi fitur sering kali tidak realistis dalam data nyata, *Naive Bayes* tetap menunjukkan kinerja yang sangat efektif, terutama dalam klasifikasi teks dengan jumlah fitur yang tinggi (Arifuddin et al., 2024).

Terdapat tiga varian utama dari algoritma *Naive Bayes* yang disesuaikan dengan jenis distribusi data (Aldoseri et al., 2023; Arifuddin et al., 2024):

a. *Gaussian Naive Bayes*: Algoritma ini digunakan untuk fitur kontinu dan berasumsi data mengikuti distribusi normal.
b. *Multinomial Naive Bayes*: Didesain untuk data diskrit dan sering digunakan dalam analisis sentimen serta pengkategorian dokumen berdasarkan frekuensi kata yang muncul.
c. *Bernoulli Naive Bayes*: Cocok untuk fitur biner yang hanya mempertimbangkan ada atau tidaknya suatu atribut (seperti "ada" atau "tidak ada").

Keunggulan utama dari *Naive Bayes* terletak pada efisiensi komputasinya yang tinggi serta kebutuhan data

pelatihan yang relatif sedikit untuk menghasilkan prediksi yang akurat. Algoritma ini sangat dapat diskalakan dan mudah dipahami karena logikanya didasarkan pada perhitungan probabilitas yang jelas. Untuk mengatasi masalah "probabilitas nol" situasi di mana suatu fitur tidak pernah muncul bersama dengan kelas tertentu dalam data pelatihan teknik *Laplace Smoothing* biasanya diterapkan untuk menjaga stabilitas model.

b) *K-Nearest Neighbors (KNN)*

K-Nearest Neighbors (KNN) merupakan algoritma pembelajaran terawasi yang beroperasi berdasarkan prinsip kesamaan fitur. *KNN* dikategorikan sebagai pembelajaran malas *(lazy learning)* karena algoritma ini tidak membangun model representatif secara langsung selama fase pelatihan. Sebaliknya, sistem menyimpan seluruh dataset pelatihan dan melakukan komputasi yang berat hanya pada tahap pengujian untuk menemukan kesamaan antara data baru dan data yang sudah ada. *KNN* juga bersifat non-parametrik, yang mengindikasikan bahwa jumlah parameternya fleksibel dan tidak tergantung pada asumsi distribusi data tertentu. Hal ini membuatnya cukup kuat dalam menangani pola data yang kompleks atau non-linear (Arifuddin et al., 2024; Goodfellow et al., 2016).

Mekanisme kerja *KNN* berfokus pada perhitungan jarak antar titik data, di mana metrik yang paling sering digunakan adalah *Jarak Euclidean*. Langkah-langkah klasifikasinya meliputi:

1) Menghitung jarak antara data baru dengan semua titik dalam dataset pelatihan.
2) Memilih k tetangga terdekat (misalnya k=5) berdasarkan jarak terkecil.
3) Menentukan kelas akhir melalui mekanisme suara mayoritas, di mana label kelas yang paling banyak muncul di antara k tetangga tersebut akan menjadi hasil prediksi.

Agar KNN dapat berfungsi secara optimal, pemilihan nilai k harus dilakukan dengan cermat. Nilai k yang terlalu kecil dapat membuat model rentan terhadap gangguan (*overfitting*), sementara k yang terlalu besar dapat mengaburkan batas antar kelas (*underfitting*). Selain itu, karena algoritma ini sangat tergantung pada perhitungan jarak, tahap normalisasi data (seperti Skala Min-Max) sangat penting agar fitur dengan skala besar tidak mendominasi fitur lainnya (Arifuddin et al., 2024; Mbete et al., 2025).

c) Random Forest

Random Forest adalah metode pembelajaran *ensemble* yang berfungsi dengan membangun banyak pohon keputusan

secara acak selama proses pelatihan. Algoritma ini dirancang untuk mengatasi kelemahan dari pohon keputusan tunggal, yang sering kali sangat dipengaruhi oleh perubahan kecil dalam data dan dapat mengalami *overfitting*. *Random Forest* mengadopsi prinsip kebijaksanaan kolektif, di mana keputusan yang diambil oleh banyak pohon keputusan biasanya jauh lebih akurat dan stabil daripada yang dihasilkan oleh satu model tunggal (Arifuddin et al., 2024).

Proses pembentukan *Random Forest* melibatkan dua teknik utama (Arifuddin et al., 2024; Mbete et al., 2025):

1) *Bagging (Bootstrap Aggregation)*: Setiap pohon dilatih dengan menggunakan subset data yang dipilih secara acak dengan pengembalian dari dataset asli, sehingga setiap pohon memperoleh "pengalaman" belajar yang berbeda.
2) *Feature Bagging*: Pada setiap pemisahan simpul, algoritma hanya mempertimbangkan subset fitur yang dipilih secara acak, bukan seluruh fitur yang ada. Tujuannya adalah untuk mengurangi korelasi antar pohon dan meningkatkan keragaman model.

Hasil prediksi akhir dari *Random Forest* dicapai melalui mekanisme voting suara terbanyak untuk klasifikasi atau rata-rata prediksi untuk regresi. Selain tingkat akurasinya yang tinggi, algoritma ini sangat bermanfaat karena mampu

memberikan estimasi kepentingan fitur, yang membantu peneliti memahami variabel mana yang paling berpengaruh terhadap target prediksi. Meskipun memerlukan lebih banyak memori dan waktu komputasi dibandingkan pohon tunggal, *Random Forest* tetap menjadi salah satu pilihan utama di industri karena ketahanannya terhadap data yang mengandung noise atau outlier (Arifuddin et al., 2024; Hazizah et al., 2025).

d) Decision Tree

Pohon keputusan atau *Decision Tree* adalah salah satu algoritma pembelajaran terawasi yang sangat terkenal karena kemampuannya dalam menyederhanakan proses pengambilan keputusan yang rumit menjadi alur logika yang mudah dipahami (Nkambule et al., 2024). Cara kerjanya mirip dengan cara berpikir manusia yang menggunakan serangkaian pertanyaan berbasis kondisi untuk mencapai kesimpulan akhir (Situmorang et al., 2025). Metode ini sangat efektif diterapkan baik dalam masalah klasifikasi maupun regresi, di mana tujuannya adalah untuk memetakan atribut-atribut data ke dalam keputusan secara terstruktur (Rafika et al., 2025).

Struktur hierarkis dari pohon keputusan terdiri dari beberapa elemen utama yang saling terhubung, yaitu Node

Akar *(Root Node),* Simpul Keputusan *(Internal Node),* Cabang *(Branches)*, dan Daun *(Leaf Node)* (Joseph, 2024).

1) Node Akar *(Root Node)*

   Node akar atau simpul akar adalah titik awal dari seluruh pohon yang merepresentasikan keseluruhan dataset sebelum pemisahan pertama dilakukan. Simpul akar umumnya memuat atribut yang dianggap paling penting atau yang memberikan informasi paling signifikan terkait variabel target.

2) Simpul Keputusan *(Internal Node)*

   Simpul keputusan adalah simpul percabangan yang mewakili pengujian terhadap atribut atau fitur tertentu dari data. Setiap simpul internal memiliki satu input dan setidaknya dua output yang menunjukkan hasil dari pengujian tersebut.

3) Cabang *(Branches)*

   Cabang adalah garis yang menghubungkan dan mewakili kemungkinan nilai atau hasil dari pengujian yang dilakukan pada simpul internal (misalnya hasil "ya" atau "tidak"). Cabang-cabang yang muncul dari setiap simpul menggambarkan hasil dari pengujian tersebut, yang kemudian mengarahkan data hingga mencapai daun.

4) Daun *(Leaf Node)*

Simpul Daun adalah simpul akhir yang tidak memiliki cabang lagi dan menyimpan label kelas (dalam kasus klasifikasi) atau nilai prediksi akhir (dalam kasus regresi). Pada daun inilah label kelas atau hasil prediksi akhir ditentukan untuk setiap objek data yang sedang dievaluasi (Mbete et al., 2025).

Proses pembuatan *Decision Tree* dilakukan melalui langkah-langkah yang disebut sebagai pemisahan rekursif *(recursive partitioning.* Langkah-langkah utamanya meliputi (Arifuddin et al., 2024; Ningsih, 2025):

a) Pemilihan atribut terbaik: menggunakan kriteria matematis seperti *Information Gain* (berdasarkan konsep Entropi), *Gain Ratio,* atau *Gini Index* guna menentukan atribut yang paling efektif dalam memisahkan data.
b) Pemisahan Dataset: Dataset dipecah menjadi subset yang lebih kecil berdasarkan nilai dari atribut yang terpilih tersebut.
c) Iterasi Rekursif: Proses penghitungan dan pemisahan ini diulangi pada setiap cabang baru hingga mencapai kondisi penghentian tertentu.

Keunggulan utama dari *Decision Tree* adalah tingkat interpretabilitas yang sangat tinggi, di mana setiap prediksi dapat dijelaskan dengan jelas melalui aturan "jika-maka" *(if-then rules)*

(Fachrezi et al., 2025). Selain itu, metode ini sangat fleksibel karena bisa menangani berbagai jenis data, baik yang berbentuk numerik maupun kategorikal, tanpa memerlukan pemrosesan data yang rumit seperti normalisasi skala (Syahra et al., 2025). Meskipun ada risiko terhadap masalah *overfitting*, hal ini dapat diatasi dengan teknik pemangkasan (*prunning*) untuk menghapus cabang-cabang yang terlalu spesifik, sehingga menghasilkan model yang lebih dapat diandalkan untuk memprediksi data baru (Ichsan, 2025).

Algoritma *Decision Tree* telah berkembang menjadi berbagai jenis yang dibuat untuk meningkatkan kinerja, efisiensi penyimpanan, serta kemampuannya dalam mengelola berbagai jenis data. Berikut adalah jenis-jenis utama dari algoritma Decision Tree (Arifuddin et al., 2024; Nazifah & Prianto, 2023):

a) *ID3 (Iterative Dichotomiser 3*)

ID3 adalah algoritma dasar yang dibuat oleh J. Ross Quinlan pada akhir tahun 1970-an. Algoritma ini menjadi dasar bagi pengembangan pohon keputusan yang modern. *ID3* memanfaatkan konsep Entropi untuk menilai tingkat ketidakpastian atau "kekacauan" dalam dataset (Russell & Norvig, 2022). Nilai informasi diukur dengan *Information Gain*, yang merupakan pengurangan nilai entropi setelah dataset dibagi berdasarkan atribut tertentu (Ichsan, 2025).

Atribut yang memberikan pengurangan ketidakpastian terbesar (Gain tertinggi) akan dipilih sebagai pemisah pada simpul tersebut (Russell & Norvig, 2022).

ID3 dirancang khusus untuk mengolah atribut kategorikal (Mbete et al., 2025). Kelemahan utama dari algoritma ini adalah ketidakmampuannya dalam menangani data yang memiliki nilai yang hilang (*missing values*) secara *default* dan adanya bias yang kuat terhadap atribut dengan banyak nilai unik (contohnya, nomor ID), yang dapat menyebabkan model menjadi kurang akurat dalam generalisasinya (A.Ningsih, 2019; Syahra et al., 2025).

b) Algoritma *C4.5*

Algoritma *C4.5* adalah salah satu metode klasifikasi yang paling terkenal dalam penambangan data, yang dikembangkan oleh Ross Quinlan sebagai perbaikan dari algoritma ID3 *(Iterative Dichotomiser 3)* (Saburina et al., 2024). Algoritma ini dirancang untuk membuat pohon keputusan dengan tingkat efisiensi dan akurasi yang tinggi (Yusuf & Sestri, 2020). Beberapa perbaikan penting pada *C4.5* meliputi kemampuannya untuk menangani atribut yang bersifat kontinu maupun diskrit, serta memiliki strategi bawaan untuk mengatasi masalah data yang hilang

(missing values) dalam dataset pelatihan (Fatah & Khafifah, 2025; Susatyono et al., 2024).

Dasar utama dari algoritma *C4.5* adalah penerapan teori informasi untuk mengevaluasi efektivitas setiap atribut dalam memisahkan data (Nazifah & Prianto, 2023; Susatyono et al., 2024). Algoritma ini menghitung nilai *Entropy* untuk mengukur tingkat ketidakpastian atau variasi dalam suatu kelas di dataset (Yusuf & Sestri, 2020). Selanjutnya, C4.5 menghitung *Information Gain* yang dinormalisasi menjadi *Gain Ratio* untuk mengatasi kelemahan *ID3* yang cenderung bias terhadap atribut dengan banyak nilai unik. Atribut yang memberikan nilai *Gain Ratio* tertinggi akan secara otomatis dipilih sebagai kriteria pemisahan di setiap simpul pohon keputusan (Fatah & Khafifah, 2025).

Dalam penelitian (Ichsan, 2025) alur proses operasional algoritma C4. 5 terdiri dari langkah-langkah berikut:

1. Inisialisasi: Mempersiapkan data pelatihan yang telah dibersihkan dan memiliki label target.
2. Perhitungan *Entropy*: Menghitung nilai *entropy* untuk setiap atribut dan variabel target guna menentukan tingkat ketidakmurnian data.

3. Perhitungan *Gain Ratio*: Menghitung perolehan informasi *(Gain)* dan rasio perolehan *(Gain Ratio)* untuk menentukan atribut yang paling penting sebagai pemisah.
4. Pembentukan *Node*: Atribut dengan *Gain Ratio* tertinggi ditetapkan sebagai *Root Node* atau simpul keputusan.
5. Iterasi Rekursif: Membuat cabang untuk setiap nilai atribut dan mengulangi proses pembagian secara rekursif sampai seluruh data terklasifikasi.
6. Pemangkasan (*Prunning*): Melakukan pemangkasan terhadap cabang yang tidak signifikan untuk meningkatkan kemampuan generalisasi model.

Hasil akhir dari penerapan algoritma *C4.5* adalah suatu struktur pohon keputusan yang mudah diubah menjadi serangkaian aturan klasifikasi yang berbasis logika bahasa alami (Yani et al., 2025). Visualisasi pohon ini memudahkan pengguna, terutama mereka yang tidak memiliki latar belakang teknis, untuk memahami faktor-faktor utama yang mendasari setiap keputusan klasifikasi yang dihasilkan oleh model (Fatah & Khafifah, 2025). Dengan tingkat akurasi yang teruji dan transparansi model yang baik, C5.0 menjadi salah satu algoritma yang umum

digunakan dalam berbagai penelitian prediksi, termasuk dalam penilaian risiko kredit dan diagnosis medis (Ichsan, 2025).

c) Algoritma *C5.0*

Algoritma *C5.0* merupakan versi terbaru dan pengembangan dari algoritma *C4.5* yang memberikan efisiensi lebih tinggi saat digunakan dalam skala besar. Algoritma ini dirancang untuk menciptakan model yang lebih akurat dengan kecepatan komputasi yang lebih cepat. Selain itu, *C5.0* sangat hemat dalam penggunaan memori, sehingga mampu memproses dataset yang jauh lebih besar dibandingkan dengan *C4.5* (Arifuddin et al., 2024).

Dalam berbagai studi kasus, seperti prediksi kematian pasien COVID-19, *C5.0* sering dikembangkan bersamaan dengan varian lain karena kemampuannya untuk menghasilkan hasil yang kompetitif dengan parameter yang lebih optimal (Mbete et al., 2025).

d) CART (Classification and Regression Trees)

Varian *CART (Classification and Regression Trees)* dikembangkan oleh Breiman pada tahun 1984 dan telah menjadi salah satu metode yang paling populer karena sifatnya yang fleksibel (A.Ningsih, 2019; Rahayu, 2011). Berbeda dengan *ID3* atau *C4.5* yang dapat memiliki banyak

cabang, *CART* selalu menghasilkan Pohon Biner, di mana setiap simpul internal selalu terpecah menjadi dua cabang saja (Rafika et al., 2025). Varian CART ini memiliki fungsi ganda, yaitu klasifikasi dan regresi (Arifuddin et al., 2024).

1) Klasifikasi: Menggunakan *Indeks Gini (Gini Impurity)* untuk mengukur tingkat ketidakmurnian suatu simpul. Semakin rendah nilai Gini, semakin efektif atribut tersebut dalam memisahkan data ke dalam kelas target yang homogen.
2) Regresi: Digunakan untuk memprediksi nilai kontinu dengan menggunakan metrik kesalahan kuadrat rata-rata *(Mean Squared Error/MSE)* atau kesalahan absolut rata-rata *(Mean Absolute Error/MAE)*.

CART menerapkan teknik pemangkasan kompleksitas biaya yang melibatkan parameter kompleksitas (α) untuk menentukan ukuran pohon yang paling optimal antara akurasi dan kesederhanaan (Prabawati & Duskarnaen, 2019).

e) CHAID (Chi-squared Automatic Interaction Detection)

CHAID adalah salah satu metode yang sering dipakai dalam penelitian kebijakan dan dukungan keputusan medis karena pendekatannya yang didasarkan pada statistik formal (Arifuddin et al., 2024). Pemisahan

simpul dilakukan berdasarkan hasil uji statistik *Chi-squared* untuk menilai pengaruh signifikan suatu atribut terhadap variabel tujuan. Algoritma ini akan terus menggabungkan atau memisahkan kategori atribut sesuai dengan tingkat signifikansi statistik yang ditentukan (A.Ningsih, 2019).

Berbeda dengan *CART* yang hanya menghasilkan pemisahan biner, *CHAID* dapat menghasilkan pemisahan *multi-way split* (lebih dari dua cabang) pada setiap simpul jika uji statistik menunjukkan adanya perbedaan signifikan antara kategori atribut (Evicienna & Amalia, 2013). Dalam berbagai penelitian klasifikasi medis, *CHAID* terbukti menunjukkan kinerja yang sangat baik, terkadang melebihi akurasi dari *CART* dan *C5.0*, seperti yang tampak dalam deteksi risiko penyakit tertentu (A.Ningsih, 2019).

Dari penjelasan yang sudah dipaparkan, maka dapat disimpulkan perbedaan dari kelima algoritma dari *Decision Tree* dalam tabel berikut:

Tabel 2. 1 Perbandingan *Algoritma Decision Tree*

Fitur / Kriteria	*ID3*	*C4.5 (J48)*	*C5.0*	*CART*	*CHAID*
Kegunaan Utama	Klasifikasi data kategorikal dasar.	Klasifikasi serbaguna untuk berbagai domain.	Klasifikasi skala besar dan data kompleks.	Klasifikasi dan Regresi (Fungsi Ganda).	Klasifikasi berbasis statistik formal.
Tipe Data Input	Hanya Kategorikal (Diskrit).	Kategorikal dan Numerik (Kontinu).	Kategorikal dan Numerik.	Kategorikal dan Numerik (Campuran).	Utamanya Kategorikal.
Struktur Pohon	*Multi-way Split* (Bisa >2 cabang).	*Multi-way Split*.	*Multi-way Split*.	*Binary Split* (Selalu 2 cabang per node).	*Multi-way Split*.
Kelebihan	Sederhana dan efisien untuk dataset kecil.	Populer, menangani data kontinu & hilang, aturan mudah dipahami.	Sangat cepat, hemat memori, akurasi lebih tinggi dari C4.5.	Fleksibel (regresi), tangguh terhadap *outlier*, efisien.	Dasar statistik yang kuat, mencegah pertumbuhan pohon yang tidak perlu.
Kelemahan	Bias pada atribut dengan banyak kategori, tidak dukung data numerik.	Bisa lambat pada dataset yang sangat masif.	Sering kali bersifat komersial/berlisensi (kurang terbuka dibanding C4.5).	Struktur biner bisa terlalu menyederhanakan hubungan data yang kompleks.	Membutuhkan ukuran sampel data yang besar agar uji statistik valid.

Sumber: Modifikasi beberapa sumber (Arifuddin et al., 2024; Fatah & Khafifah, 2025; Mbete et al., 2025)

B. Penelitian Terdahulu

Penelitian ini berkaitan dengan penelitian sebelumnya untuk dijadikan acuan dan perbandingan. Berikut penelitian para terdahulu sebagai pedoman pada penelitian ini dirangkum dalam tabel 2.1 sebagai berikut

Tabel 2. 2 Penelitian Terdahulu

No	Judul Penelitian, nama penulis & tahun terbit	Variabel	Metode penelitian	Hasil
1.	*Factors Influencing Loan Default: An Empirical Analysis Based on Microscopic Evidence* (Xu, 2025)	**Variabel X:** 1. Pendapatan & Lama Kerja 2. DTI, Tenor, Loan Amount 3. Suku Bunga **Variabel Y:** *Default Probability*	Pendekatan kuantitatif menggunakan *Logit Model* dan *Probit Regression*.	1. Pendapatan tahunan dan lama kerja berpengaruh negatif thd *default probability*. 2. DTI, tenor, dan *loan amount* berpengaruh positif thd *default probability*. 3. Suku bunga berpengaruh positif thd *default probability*.
2.	*Machine Learning XAI for Early Loan Default Prediction* (Monje et al., 2025)	**Variabel X:** 1. Tenor Pinjaman Riwayat Kredit 2. Soft Info (Komentar) **Variabel Y:** *Early Loan Default*	Pendekatan kuantitatif menggunakan *XGBoost, BiLSTM, GCNs, dan Explainable AI (XAI).*	1. Tenor pinjaman (60 bulan) dan Riwayat kredit berpengaruh positif thd *early loan default prediction*.
3.	*Determinants of Loan Default in P2P Lending: Evidence Across Time and Borrower Subgroups.* (Pas, 2025)	**Variabel X:** 1. Gender (perempuan) 2. Pendidikan tingg 3. Liabilitas & rating **Variabel Y:** *Probability of Default*	Pendekatan kuantitatif melalui *Multiple Logistic Regression* dan analisis subkelompok.	1. Gender (perempuan) berpengaruh negatif thd *probability of default*. 2. Tingkat pendidikan tinggi berpengaruh negatif thd *probability of default* 3. Liabilitas dan rating internal berpengaruh positif thd *probability of default*.

No	Judul Penelitian, nama penulis & tahun terbit	Variabel	Metode penelitian	Hasil
4.	*Relationship between Interest Rates and Loan Default Rates A Case Study of Commercial Banks in Uganda* (Christopher & Moses, 2025)	**Variabel X:** 1. Suku bunga 2. Tingkat pendapatan 3. Literasi keuangan Variabel Y: Tingkat gagal bayar	Analisis Regresi Linier Berganda	1. Kenaikan suku bunga pinjaman berpengaruh signifikan terhadap peningkatan tingkat gagal bayar 2. Tingkat pendapatan nasabah berpengaruh terhadap kemampuan pembayaran kembali
5.	Analisa Faktor-Faktor Keputusan Kredit dan Potensi Gagal Bayar Pada *Platform Peer To Peer Lending* (E. Larasati et al., 2025)	Variabel X: 1. Literasi keuangan 2. Sosiodemografi (usia, pendapatan, jenis kelamin) 3. Efikasi diri finansial Variabel Y: 1. Keputusan kredit 2. Potensi gagal bayar	SEM-PLS	1. Literasi keuangan berpengaruh signifikan terhadap potensi gagal bayar (individu melek finansial lebih rendah risikonya). 2. Faktor sosiodemografi berpengaruh signifikan terhadap keputusan kredit dan potensi gagal bayar. 3. Efikasi diri finansial berpengaruh signifikan terhadap manajemen risiko gagal bayar. 4. Literasi keuangan tidak memiliki pengaruh langsung yang signifikan terhadap keputusan kredit
6.	Penerapan Algoritma *Decision Tree* untuk Memprediksi Risiko Kredit pada Nasabah Bank (Mbete et al., 2025)	**Variabel X:** 1. Pendapatan, 2. Besaran cicilan, 3. Uang muka, 4. Usia, 5. Tagihan listrik, 6. Tagihan telepon, 7. Rekening tabungan, 8. Jangka waktu pinjaman. **Variabel Y:** Risiko gagal bayar nasabah bank.	*Decision Tree* dengan tahapan *preprocessing data, training model, pruning, sampling, Information Gain, Entropy*	1. Variabel pendapatan menjadi salah satu faktor dominan dalam prediksi risiko kredit. 2. Besaran cicilan, uang muka, dan jangka waktu pinjaman memengaruhi tingkat risiko gagal bayar. Variabel usia, tagihan listrik, dan tagihan telepon digunakan sebagai indikator kemampuan finansial nasabah.

No	Judul Penelitian, nama penulis & tahun terbit	Variabel	Metode penelitian	Hasil
7.	Penerapan Algoritma *Decision Tree* untuk Memprediksi *Default* Kredit (Situmorang et al., 2025)	**Variabel X:** 1. Limit kredit 2. Jenis kelamin 3. Tingkat pendidikan 4. Status pernikahan 5. Umur 6. Riwayat pembayaran 7. Jumlah tagihan bulanan 8. Jumlah pembayaran bulanan **Variabel Y:** *Default* kredit / risiko gagal bayar	*Decision Tree Classifier*	1. Model *Decision Tree* memperoleh akurasi 91% dalam klasifikasi risiko kredit. 2. Variabel riwayat pembayaran menjadi faktor paling berpengaruh dalam prediksi default kredit. 3. Variabel limit pinjaman memengaruhi kapasitas finansial nasabah dan keputusan klasifikasi. 4. Variabel jumlah tagihan dan pembayaran bulanan menunjukkan beban serta kemampuan pembayaran nasabah. 5. Variabel usia memengaruhi profil risiko dan stabilitas ekonomi nasabah.
8.	*A Comparative Analysis of Consumer Credit Risk Models in a Comparative Analysis of Consumer Credit Risk Models in Peer-To-Peer Lending* (Trinh, 2024)	**Variabel X:** 1. Tenor (*term*) 2. Skor FICO3. 3. 150 fitur lainnya **Variabel Y:** *Consumer Credit Risk (Default)*	Pendekatan kuantitatif membandingkan model GBDT, *XGBoost, Random Forest*, dan *Logistic Regression*.	1. Tenor (*term*) berpengaruh positif thd *consumer credit risk*. 2. Skor FICO berpengaruh negatif thd *consumer credit risk*.
9.	*Estimating Probability of Default via Delinquencies Evidence from European P2P Lending Market* (Nigmonov et al., 2024)	**Variabel X:** 1. Imbal Hasil Pasar Saham 2. Suku Bunga Negara 3. Makroekonomi (GDP, Inflasi) **Variabel Y:** *Probability of Default*	Pendekatan kuantitatif melalui *Logit Estimation*, LASSO, dan *Instrumental Variables*.	1. Suku bunga negara berpengaruh positif thd *probability of default* agregat. 2. Imbal hasil pasar saham berpengaruh positif thd *probability of default*.

No	Judul Penelitian, nama penulis & tahun terbit	Variabel	Metode penelitian	Hasil
10.	*Evaluation of Factors Affecting Credit Default Risk in Banking in Turkey* (Şahin, 2024)	**Variabel X:** 1. Indikator makro (GDP, inflasi, suku bunga) 2. Pola perilaku belanja **Variabel Y:** *Default Probabilities*	Pendekatan kuantitatif melalui metode *desk research* dan regresi logistik.	Indikator makroekonomi berpengaruh positif thd *default probabilities*.
11.	*Machine Learning-Based Loan Default Prediction in Peer-to-Peer Lending* (Yang, 2024)	**Variabel X:** *1. Last fico range high,* *2. Last fico range low,* *3. Acc now delinq,* *4. Delinq amnt,* *5. Annual income,* *6. Loan amount,* *7. Feature engineering,* 8. *Balancing dataset***.** **Variabel Y:** *Loan default prediction / risiko gagal bayar pinjaman***.**	Pendekatan kuantitatif menggunakan *Machine Learning (Logistic Regression, Decision Tree, KNN, Random Forest, Gradient Boosting, LightGBM, XGBoost, Bagging, Stacking*).	1. Variabel *last_fico_range_high* dan *last fico range low* berpengaruh signifikan terhadap risiko gagal bayar. 2. Variabel *acc now delinq*, *delinq amnt, loan amount* menjadi faktor penting dalam prediksi *default*. 3. *Feature engineering* dan *balancing* dataset meningkatkan performa model prediksi. *Ensemble learning* memberikan hasil prediksi yang lebih baik dibanding model tunggal
12.	*Machine Learning-Based Loan Default Prediction: Models, Insights, and Performance Evaluation in Peer-to-Peer Lending Platforms* (Jayaram et al., 2024)	**Variabel X:** *1. Loan amount,* *2. Interest rate,* *3. Annual income,* *4. Debt-to-income ratio (dti),* *5. Fico score,* *6. Employment tenure,* *7. Home ownership,* *8. Loan purpose,* **9.** *Borrower creditworthiness***.** **Variabel Y:** *Loan default prediction / default risk.*	Pendekatan kuantitatif menggunakan *Deep Learning dan Machine Learning* berbasis Python serta analisis statistik deskriptif.	1. Tingkat suku bunga dan inflasi meningkatkan probabilitas gagal bayar. 2. *Loan amount* dan *debt-to-income ratio* berpengaruh terhadap risiko *default.* 3. *FICO score* dan *creditworthiness* memengaruhi kemampuan pembayaran pinjaman. 4. Model *machine learning* mampu meningkatkan

No	Judul Penelitian, nama penulis & tahun terbit	Variabel	Metode penelitian	Hasil
				akurasi prediksi risiko gagal bayar.
13.	Penerapan Algoritma *C4.5* Untuk Memprediksi Kredit Macet Pada Sistem Pinjaman Digital Di Industri *FinTech* (Susatyono et al., 2024)	**Variabel X:** 1. Status pekerjaan 2. Pendapatan, 3. Riwayat pembayaran, 4. Usia, 5. Pendapatan bulanan, 6. Jumlah pinjaman, 7. Status pernikahan, 8. Riwayat kredit. **Variabel Y:** Kredit macet pada sistem pinjaman digital *Fintech*	*Algoritma C4.5 (Decision Tree)*	1. Algoritma *C4.5* mampu menangani atribut numerik dan kategorikal dalam prediksi kredit macet. 2. Variabel pendapatan, status pekerjaan, dan riwayat kredit memengaruhi kemungkinan kredit macet. 3. Nasabah dengan pendapatan rendah dan riwayat kredit buruk memiliki risiko kredit macet lebih tinggi. 4. Pohon keputusan mempermudah identifikasi faktor yang memengaruhi keputusan kredit. Model menghasilkan akurasi sebesar 89,6% dalam prediksi kredit macet sehingga membantu pengelolaan risiko pada industri *Fintech*
14.	*The Impact of Conventional and Unconventional Monetary Policies On Loan Default Risk* (Vu, 2023)	**Variabel X**: 1. Kebijakan Moneter (*Shadow Rate*) 2. Durasi Pinjaman 3. Jumlah Pinjaman 4. Suku Bunga 5. Riwayat Gagal Bayar. **Variabel Y**: Risiko gagal bayar pinjaman	Pendekatan kuantitatif melalui *Accelerated Failure Time (AFT) Regression* dan *Cox Regression*.	1. Pelonggaran kebijakan moneter berpengaruh positif thd *loan default risk*. 2. Suku bunga pinjaman berpengaruh positif thd *loan default risk*. Riwayat gagal bayar berpengaruh positif thd *loan default risk*

No	Judul Penelitian, nama penulis & tahun terbit	Variabel	Metode penelitian	Hasil
15	*Factors Determining Default in P2P Lending*. (Avgeri & Psillaki, 2023)	**Variabel X:** 1. Atribut Pinjaman (Limit, *Grade*) 2. Kondisi Peminjam (DTI, Pendapatan) **Variabel Y:** *Default Status*	Pendekatan kuantitatif menggunakan *Binary Logistic Regression* dengan *robust standard errors*.	1. Rating kredit (*grade*) berpengaruh positif thd *default status*. 2. DTI berpengaruh positif thd *default status*. 3. *Loan amount* berpengaruh positif thd *default status*.
16	*Impact of Gender, Age and Education of Peer-to-Peer Lender on Loan Viability Assessment: Evidence from Sharia Firm* (Maulia & Yohanna, 2023)	Variabel X: 1. Gender 2. Usia Lender 3. Pendidikan **Variabel Y:** *Loan Default*	Pendekatan kuantitatif melalui metode *Logistic Regression* terhadap data perusahaan *P2P* Syariah.	1. Usia lender berpengaruh negatif thd *loan default* (lender tua lebih teliti). 2. Interaksi gender perempuan dan pendidikan tinggi berpengaruh negatif thd *loan default*.
17.	*Peer-to-Peer (P2P) Lending in Europe: Evaluating the Default Risk of Borrowers in the Context of Gender and Education* (Aliano, 2023)	**Variabel X:** 1. Gender 2. Pendidikan tinggi 3. Suku bunga & liabilitas **Variabel Y:** *Probability of Default*	Pendekatan kuantitatif menggunakan *Logit Model* dan *Principal Component Analysis (PCA)*.	1. Gender (perempuan) berpengaruh negatif thd *probability of default*. 2. Pendidikan tinggi berpengaruh negatif thd *probability of default*. 3. Suku bunga dan liabilitas berpengaruh positif thd *probability of default*.
18.	*Peer-to-Peer (P2P) Lending in Europe: Evaluating the Default Risk of Borrowers in the Context of Gender and Education* (Aliano, 2023)	**Variabel X:** 1. Gender 2. Pendidikan **Variabel Y**: *Default Risk*	Pendekatan kuantitatif menggunakan regresi logistik.	1. Gender (perempuan) berpengaruh thd penurunan *default risk*. 2. Pendidikan tinggi berpengaruh negatif thd *default risk*.
19	*Identifying gender disparities on the time to repay microfinance group loans:*	**Variabel X** 1. Gender 2. Faktor makro (remitansi) **Variabel Y:**	Pendekatan kuantitatif menggunakan *Multivariate AFT Survival Analysis*.	1. Gender berpengaruh thd perbedaan *time to default*. 2. Faktor makro (remitansi) berpengaruh thd

No	Judul Penelitian, nama penulis & tahun terbit	Variabel	Metode penelitian	Hasil
	Evidence from Mexico (Bátiz-zuk & González-holden, 2023)	*Time to Default*		pelunasan/waktu gagal bayar.
20.	*Prediction of Micro and Small Sized Enterprise Default Risk Based on a Logistic Model: Evidence from a Bank of China* (Zhao & Lin, 2023)	**Variabel X:** *1. Quick ratio* *2. Total asset turnover* *3. Return on net assets* *4. Sales growth rate* *5. Total assets growth rate* *6. Loan maturity* *7. Loan amount* *8. Nature of enterprise* *9. Method of obtaining loan* *10. Educational background of manager.* **Variabel Y:** *Default risk* perusahaan mikro dan kecil.	Pendekatan kuantitatif menggunakan *Logistic Regression Model*.	1. *Quick ratio* berpengaruh negatif terhadap risiko gagal bayar. 2. *Total asset turnover* berpengaruh negatif terhadap default risk. 3. *Return on net assets* menurunkan risiko gagal bayar. 4. *Sales growth rate* dan *total assets growth rate* berpengaruh negatif terhadap default risk. 5. *Loan maturity* dan *loan amount* berpengaruh positif terhadap risiko gagal bayar. 6. *Nature of enterprise, method of obtaining loan,* dan *educational background* pimpinan perusahaan memengaruhi default risk
21.	*Unwarranted Gender Disparity in Online P2P Lending: Evidence of Affirmative Action* (Shen et al., 2022)	**Variabel X:** 1. Gender *2. Return rate* **Variabel Y:** *Funding Success & Default*	Pendekatan kuantitatif melalui *two-stage approach (2SPS)* dengan *Bayesian Inference*.	1. Gender (perempuan) berpengaruh positif thd *funding success* (lebih mudah didanai).
22.	*P2P Lending Default Prediction Based on AI and Statistical Models*	**Variabel X:** 1. Suku bunga & skor kredit 2. Jenis algoritma *(LightGBM)* **Variabel Y:**	Pendekatan kuantitatif membandingkan algoritma statistik dan *AI (CNN, ANN, LightGBM).*	1. Suku bunga dan skor kredit berpengaruh positif thd default prediction 2. Jenis algoritma (*LightGBM*) berpengaruh positif

No	Judul Penelitian, nama penulis & tahun terbit	Variabel	Metode penelitian	Hasil
	(Ko et al., 2022)	*Default Prediction*		thd akurasi *default prediction*.
23.	Pengaruh Tingkat Suku Bunga dan Jangka Waktu Terhadap Kredit Macet (Studi Kasus pada Koperasi Syariah Masyarakat Kertasinduyasa, Jatibarang, Brebes) (Astuti et al., 2022)	**Variabel X** 1. Tingkat suku bunga 2. Jangka waktu **Variabel X** Kredit macet	Analisis Regresi (Uji T & F)	1. Tingkat suku bunga berpengaruh secara signifikan terhadap peningkatan risiko kredit macet 2. Jangka waktu (tenor) tidak berpengaruh signifikan terhadap variabel kredit macet
24.	*A Longitudinal Systematic Review of Credit Risk Assessment and Credit Default Predictors* (Çallı & Coşkun, 2021)	**Variabel X:** 1. Faktor Sosioekonomi 2. Demografi 3. Perilaku & Psikologi **Variabel Y**: *Probability of Default*	Pendekatan kuantitatif melalui *Systematic Review* (PRISMA) terhadap 108 studi terdahulu.	1. Peristiwa hidup yang buruk (*adverse life events*) berpengaruh positif thd *probability of default*. 2. Literasi keuangan berpengaruh negatif thd tingkat utang bermasalah.
25.	*Default Probability Prediction Using Peer-To-Peer Lending Interest Rate Determinants adnd Machine Learning* (Snakkers, 2021)	**Variabel X**: 1. Suku Bunga 2. Rating Kredit 3. Demografi **Variabel Y:** *Default Prediction*	Pendekatan kuantitatif menggunakan *Lasso model*, *OLS regression*, dan *Machine Learning*.	1. Suku bunga berpengaruh positif thd *default prediction*. 2. Rating kredit berpengaruh signifikan thd *default prediction*.
26.	*P2P Lending, Default, Default Dependency and Industry Potential* (Mammadova, 2021)	**Variabel X:** 1. Pertumbuhan GDP 2. Tingkat pengangguran 3. Jumlah pinjaman **Variabel Y:** *Default rate*	Regresi Logistik	1. Pertumbuhan GDP berpengaruh negatif terhadap gagal bayar. 2. Tingkat pengangguran berpengaruh positif terhadap *default rate.* 3. Jumlah pinjaman (*loan amount*) berpengaruh positif

No	Judul Penelitian, nama penulis & tahun terbit	Variabel	Metode penelitian	Hasil
				signifikan terhadap probabilitas gagal bayar
27.	*Liquidity Default and Progressive Lending in Microfinance: A Lab in the Field Experiment in Bolivia* (Cecchi et al., 2021)	**Variable X:** *1. Progressive Lending* 2. Limit Kredit 3. Karakteristik Persolan (Usia, Gender, Pendidikan) **Variabel Y:** 1. *Liquidity default* 2. *Overborrowing*	Pendekatan kuantitatif dg metode *Ordinary Least Square (OLS) Regression*	1. *Progressive Lending* berpengaruh positif thd *overborrowing* dan *liquidity default* 2. Gender Perempuan berpengaruh *negative* thd *liquidity default*
28.	*Determinants of Loan Default in Peer-to- Peer Lending at Different Loan Risk Levels* (Rodrigues, 2020)	**Variabel X:** 1. Pendapatan Tahunan 2. Skor Fico 3. Dti & Suku Bunga **Variabel Y:** *Default Status*	Pendekatan kuantitatif menggunakan *Binary Logistic Regression* pada *platform* Lending Club & Prosper.	1. Pendapatan tahunan berpengaruh negatif thd *default status*. 2. Skor FICO berpengaruh negatif thd *default status*. 3. DTI dan suku bunga berpengaruh positif thd *default status*.
29.	*Prediction of Default Risk in Peer-to-Peer Lending Using Structured and Unstructured Data* (Lee, 2020)	**Variabel X**: 1. Suku bunga 2. Jumlah pinjaman, 3. *Sentiment score* deskripsi 4. Pendapatan 5. DTI **Variabel Y**: Risiko gagal bayar	*Binary Probit Model*	1. *Sentiment score* deskripsi pinjaman berpengaruh negatif terhadap risiko gagal bayar (skor tinggi menurunkan risiko) 2. Suku bunga, jangka waktu pinjaman, dan rasio utang (DTI) berpengaruh positif signifikan terhadap risiko gagal bayar. 3. Pendapatan tahunan berpengaruh negatif terhadap risiko gagal bayar
30.	*Loan Default Prediction Based on Machine Learning Approaches* (Cai et al., 2020)	**Variabel X:** *1. Loan grade* *2. Annual income* *3. Loan amount* *4. Credit history length* *5. Dti ratio* *6. Interest rate* *7. Installment*	Pendekatan kuantitatif menggunakan *Decision Tree, Random Forest, AdaBoost, Bagging, XGBoost,*	1. *Ensemble learning* memiliki akurasi lebih tinggi dibanding algoritma tunggal. 2. *CatBoost* menjadi model terbaik dalam memprediksi default

No	Judul Penelitian, nama penulis & tahun terbit	Variabel	Metode penelitian	Hasil
		8. Home ownership *9. Employment length.* **Variabel Y:** *Loan default prediction / customer default***.**	*LightGBM, dan CatBoost*	berdasarkan nilai *AUC*. 3. *Loan grade* berpengaruh signifikan terhadap risiko gagal bayar. 4. *Annual income, loan amount,* dan *DTI ratio* memengaruhi kemungkinan default. 5. *Credit history length* berhubungan dengan tingkat risiko kredit nasabah.

C. Kerangka Konseptual

Kerangka berpikir adalah suatu ide yang diimplementasikan untuk menjelaskan keterkaitan antara variabel dalam sebuah studi dengan cara yang logis dan terstruktur. Kerangka ini menjadi pedoman dalam merancang penelitian serta berfungsi sebagai dasar untuk menyusun hipotesis dan paradigma penelitian. Melalui kerangka konseptual, peneliti dapat menguraikan hubungan antara variabel bebas dan variabel terikat dari perspektif teoretis (Sugiyono, 2023).

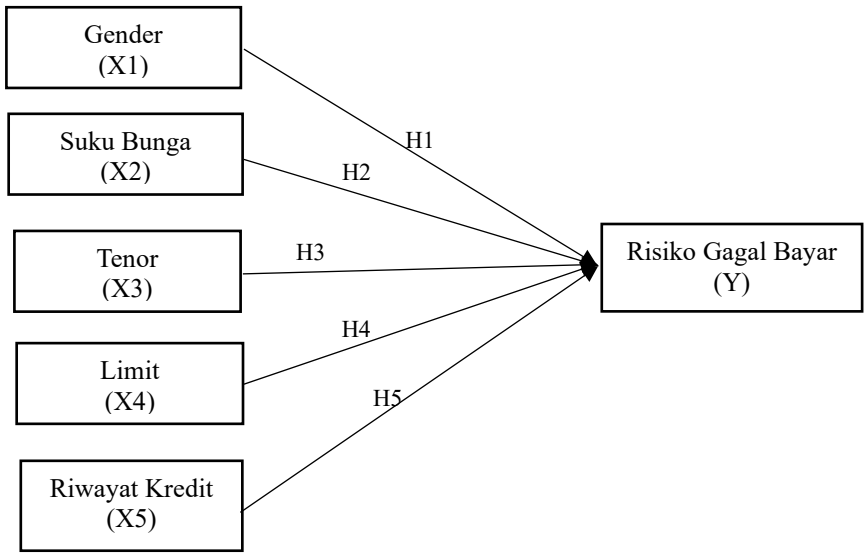
Kerangka penelitian yang diterapkan dalam penelitian ini berfungsi sebagai panduan untuk menetapkan langkah-langkah terstruktur, sehingga pembahasan pada tahap awal dapat menjadi dasar bagi analisis selanjutnya. Dalam kerangka yang telah ditetapkan, variabel (X1) *Gender*, (X2) Suku Bunga, (X3) Tenor Pinjaman, (X4) Limit Pinjaman, (X5) Riwayat Kredit memengaruhi (Y) Risiko Gagal Bayar.

Penelitian oleh Aliano (2023), mengungkapkan bahwa faktor gender memiliki pengaruh signifikan terhadap kemungkinan gagal bayar. Dalam hal ini, peminjam perempuan terbukti berkontribusi positif dalam mengurangi tingkat risiko gagal bayar dibandingkan dengan peminjam laki-laki. Ini menunjukkan bahwa sifat perilaku keuangan perempuan yang cenderung lebih berhati-hati dapat mengurangi kemungkinan terjadinya wanprestasi pada *platform* pinjaman *peer-to-peer (P2P lending).* Penelitian oleh Astuti et al. (2022), menunjukkan bahwa suku bunga mempunyai pengaruh positif dan signifikan terhadap risiko kredit bermasalah. Artinya, semakin tinggi suku

bunga yang dibebankan kepada debitur, semakin besar kemungkinan terjadi kegagalan dalam pengembalian pinjaman.

Selanjutnya, penelitian oleh Suteja (2025), menjelaskan bahwa tenor atau jangka waktu pinjaman berpengaruh terhadap risiko gagal bayar. Semakin lama periode pinjaman yang disepakati, semakin tinggi risiko peminjam untuk tidak dapat memenuhi kewajibannya, yang disebabkan oleh kemungkinan perubahan kondisi ekonomi mereka selama periode tersebut. Penelitian oleh Yusuf et al. (2025), menyatakan bahwa penetapan limit kredit juga berpengaruh pada risiko gagal bayar. Pemberian limit yang terlalu tinggi dan tidak sesuai dengan kapasitas pendapatan nasabah dapat meningkatkan risiko kredit bermasalah bagi lembaga keuangan. Terakhir, penelitian oleh Sifrain (2023), menekankan bahwa riwayat kredit merupakan salah satu variabel utama yang sangat berpengaruh dalam memprediksi risiko gagal bayar. Data historis pembayaran nasabah di masa lalu menjadi indikator yang kuat untuk menentukan kemampuan bayar mereka di masa mendatang.

Berdasarkan teori dan penelitian sebelumnya yang diuraikan di atas, dapat disimpulkan gender (X1), suku bunga (X2), tenor pinjaman (X3), limit pinjaman (X4), dan riwayat kredit (X5) berpengaruh terhadap risiko gagal bayar (Y). Kelima variabel tersebut berperan sebagai faktor faktor yang dapat mempengaruhi risiko gagal bayar. Untuk menjelaskan lebih lanjut masalah penelitian ini, kerangka konseptual dirancang dan disajikan secara skematis pada Gambar 2.1.



Gambar 2. 1 Kerangka Konseptual

Sumber: Modifikasi dari kerangka konseptual (Astuti et al., 2022)

D. Hipotesis Penelitian

1. Pengaruh Gender Terhadap Risiko Gagal Bayar

Gender merupakan salah satu karakteristik sosiodemografi atau identitas personal yang membedakan peran sosial dan biologis antara pria dan wanita. Gender adalah salah satu sifat demografis yang sering kali terbukti memiliki hubungan yang kuat dengan tingkah laku keuangan serta kemungkinan terjadinya gagal bayar dari nasabah (Aliano, 2023). Dalam konteks penelitian ini, variabel gender diukur menggunakan indikator biner, yaitu kategori laki-laki dan perempuan.

Hubungan antara gender dan tingkat risiko diuraikan melalui teori keuangan perilaku *(finance behavior)*, khususnya terkait dengan konsep penghindaran risiko dan bias psikologis (Maulia & Yohanna, 2023). Teori ini menegaskan bahwa keputusan keuangan tidak hanya dipengaruhi

logika, tetapi juga faktor emosional (Febrianty et al., 2024). Perbedaan gender memengaruhi cara seseorang mengelola keuangan dan membuat keputusan terkait utang. Umumnya, pria lebih cenderung untuk mengambil risiko, menggunakan logika, dan menunjukkan tingkat kepercayaan diri yang tinggi, yang dapat menyebabkan mereka berpotensi terjerat utang yang berlebihan. Di sisi lain, wanita lebih berhati-hati, menghindari risiko, dan melakukan analisis yang cermat sebelum melakukan transaksi keuangan. Hal ini menunjukkan bahwa keputusan finansial tidak hanya berdasarkan logika semata, tetapi juga dipengaruhi oleh faktor emosional serta perbedaan pola pikir antara jenis kelamin.

Beberapa penelitian menunjukkan bahwa perempuan cenderung lebih berhati-hati dalam mengambil risiko dibandingkan dengan laki-laki ketika membuat keputusan keuangan (Bátiz-zuk & González-holden, 2023). Menurut hasil studi Aliano et al. (2023), perempuan sebagai nasabah memberikan dampak positif dalam mengurangi kemungkinan gagal bayar setelah periode tertentu. Ini sejalan dengan hasil penelitian Chen et al. (2021), yang menunjukkan bahwa meminjamkan uang kepada perempuan berhubungan dengan hasil pinjaman yang lebih baik, karena kemungkinan gagal bayar yang lebih rendah.

Berdasarkan hubungan antar variabel yang telah dijelaskan sebelumnya, maka dirumuskan hipotesis sebagai berikut:

H1: Gender berpengaruh terhadap Risiko Gagal Bayar.

2. Pengaruh Suku Bunga Terhadap Risiko Gagal Bayar

Suku bunga adalah komponen penting dalam biaya pinjaman yang secara langsung mempengaruhi beban keuangan peminjam serta kemampuan mereka untuk membayar utang (Suteja, 2025). Tingkat suku bunga yang tinggi cenderung meningkatkan risiko terjadinya kredit macet karena menambah beban pembayaran bunga yang harus ditanggung oleh peminjam setiap bulannya (Astuti et al., 2022). Dalam lingkup *P2P Lending*, indikator yang digunakan untuk mengukur variabel ini adalah suku bunga harian (termasuk biaya layanan) yang dibatasi oleh regulasi OJK (OJK-WP, 2018).

Dalam teori risiko kredit, suku bunga berperan sebagai mekanisme penetapan harga berdasarkan risiko untuk menutupi perkiraan kerugian dengan mengenakan premi yang lebih tinggi kepada nasabah yang berisiko (Rau & Shuaib, 2022; Şahin, 2024). Namun, menurut teori informasi asimetris, suku bunga yang terlalu tinggi dapat menyebabkan *adverse selection*, di mana peminjam yang berkualitas baik akan menarik diri dari pasar, sementara peminjam yang berisiko tinggi tetap ada karena tidak memiliki niat yang baik untuk membayar (Avgeri & Psillaki, 2023; Nigmonov et al., 2024).

Keterkaitan antara suku bunga dan risiko gagal bayar bergantung pada kemampuan finansial debitur. Meningkatnya suku bunga akan mengakibatkan tekanan likuiditas yang lebih besar serta berpotensi

memunculkan risiko pemilihan peminjam yang kurang tepat, yang pada akhirnya dapat meningkatkan kemungkinan terjadinya gagal bayar. Dapat disimpulkan bahwa suku bunga bukan hanya sekadar biaya biasa, tetapi sebagai alat untuk menyaring risiko,. Apabila suku bunga ditentukan terlalu tinggi, beban cicilan akan meningkat melebihi batas kemampuan debitur. Penumpukan bunga dan denda tersebut akan secara signifikan memperbesar total utang, sehingga memperburuk profil risiko peminjam.

Hal ini diperkuat oleh penelitian Nigmonov et al. (2024) yang menyatakan bahwa suku bunga yang lebih tinggi secara signifikan meningkatkan risiko tidak bayar pada pinjaman dalam pasar *P2P Lending*. Sejalan dengan itu, penelitian oleh Astuti et al. (2022) menyimpulkan adanya pengaruh positif dan signifikan dari variabel suku bunga terhadap risiko kredit macet.

Berdasarkan hubungan antar variabel yang telah dijelaskan, hipotesis dirumuskan sebagai berikut:

H2: Suku Bunga memiliki pengaruh terhadap Risiko Gagal Bayar.

3. Pengaruh Tenor Pinjaman Terhadap Risiko Gagal Bayar

Tenor atau jangka waktu pinjaman adalah periode yang disetujui untuk melunasi utang, di mana durasi ini sering kali mencerminkan ketidakpastian kondisi ekonomi peminjam di masa mendatang (Johnston, 2020). Dalam penelitiannya, Suteja (2025) menyatakan bahwa tenor pinjaman adalah faktor internal yang penting yang dapat mempengaruhi

terjadinya gagal bayar pada *platform P2P lending*. Indikator yang digunakan untuk mengukur variabel ini meliputi *term/duration* (pilihan periode tetap seperti 36 atau 60 bulan), *loan maturity* (tanggal akhir pelunasan), serta *survival time* yang mengukur durasi sejak pinjaman diberikan hingga terjadi pelunasan atau gagal bayar (Avgeri & Psillaki, 2023).

Dalam teori risiko kredit, tenor menggambarkan durasi paparan terhadap risiko, di mana periode yang lebih lama dapat meningkatkan ketidakpastian mengenai keadaan ekonomi peminjam di masa mendatang (Astuti et al., 2022). Di sisi lain, teori perilaku keuangan menekankan konsep *present-bias*, yaitu kecenderungan individu untuk melebih-lebihkan kemampuan finansial di masa depan, sehingga mereka cenderung mengambil tenor yang panjang tanpa perencanaan yang matang (Johnston, 2020).

Keterkaitan antara tenor dan risiko gagal bayar berfokus pada cara nasabah mengelola pembayaran cicilan dalam situasi yang tidak pasti di masa depan. Semakin lama jangka waktu pinjaman yang disepakati, semakin besar kemungkinan peminjam tidak dapat memenuhi kewajibannya karena kemungkinan adanya perubahan dalam kondisi keuangan mereka selama jangka waktu tersebut (Aleksandrova, 2021). Penetapan tenor yang tidak tepat dapat menyebabkan beban cicilan menjadi tidak seimbang dengan arus kas yang diterima oleh nasabah, sehingga dapat disimpulkan bahwa tenor yang lebih pendek memiliki

keuntungan tertentu. Jangka waktu yang lebih singkat ini dapat mendorong kedisiplinan dan rasa tanggung jawab yang lebih besar bagi nasabah untuk menyelesaikan utangnya dengan segera tanpa menunda-nunda.

Hal ini diperkuat oleh beberapa penelitian, Astuti et al. (2022) dan Suteja (2025), menyatakan bahwa semakin lama periode pinjaman, semakin meningkat kemungkinan terjadinya gagal bayar. Selain itu, Johnston (2020) mendukung argumen bahwa pengaturan tenggat waktu yang lebih pendek dapat memacu tanggung jawab debitur atas utang mereka

Berdasarkan hubungan antara variabel-variabel yang telah dijelaskan sebelumnya, dapat dirumuskan hipotesis sebagai berikut:

H3: Tenor berpengaruh terhadap Risiko Gagal Bayar.

4. Pengaruh Limit Pinjaman Terhadap Risiko Gagal Bayar

Limit kredit adalah jumlah maksimum dana yang diberikan kepada seorang nasabah, yang sebaiknya ditentukan berdasarkan analisis mengenai pendapatan dan kemampuan bayar nasabah tersebut (Twesiime et al., 2024). Indikator yang digunakan untuk mengukur variabel ini meliputi *Applied Amount* (besaran dana yang diajukan), *Funded Amount* (total pinjaman yang disetujui), dan *Loan Size* (klasifikasi besar pinjaman) (Vu, 2023).

Dalam teori risiko kredit, batasan pinjaman yang besar dianggap meningkatkan kemungkinan gagal bayar karena tingginya beban

pengembalian dibandingkan kemampuan pendapatan peminjam (Nigmonov et al., 2024). Melalui sudut pandang teori asimetri informasi, jumlah pinjaman yang tinggi dapat menimbulkan isu *moral hazard*, di mana peminjam cenderung lebih mementingkan kepentingan pribadi dibandingkan kepentingan investor setelah dana dicairkan (Vu, 2023).

Hubungan antara limit pinjaman dan risiko gagal bayar terletak pada jumlah kewajiban yang dimiliki nasabah. Semakin tinggi batas pinjaman yang diberikan, semakin besar pula angsuran yang harus dibayar, sehingga peluang untuk tidak membayar akan meningkat jika kewajiban tersebut melebihi kemampuan finansial aktual nasabah (Nigmonov et al., 2024). Oleh karena itu, peneliti berpendapat bahwa penetapan limit pinjaman yang tepat sangat penting bagi *platform* untuk menjaga kualitas kredit dan menghindari kerugian akibat pemberian pinjaman yang berlebihan.

Penelitian yang dilakukan oleh Yusuf et al. (2025), mengemukakan bahwa penentuan limit kredit yang akurat sangat penting bagi lembaga keuangan dalam mengelola risiko gagal bayar dari nasabah. Penelitian Lee (2020), Nigmonov et al. (2024) dan Sifrain (2023), menyatakan bahwa limit yang terlalu besar dapat beresiko terhadap pengembalian. Selain itu, penelitian oleh Xu (2025)**,** membuktikan bahwa setiap tambahan satu unit/*platform* pinjaman meningkatkan risiko kredit bermasalah, sementara Thi et al. (2021), mengonfirmasi bahwa jumlah

pinjaman yang lebih rendah cenderung memiliki performa pengembalian yang lebih baik

Berdasarkan hubungan antar variabel yang telah diuraikan sebelumnya, maka hipotesis dirumuskan sebagai berikut:

H4: Limit berpengaruh terhadap Risiko Gagal Bayar.

5. Pengaruh Riwayat Kredit Terhadap Risiko Gagal Bayar

Riwayat kredit diartikan sebagai pencatatan yang objektif mengenai perilaku pembayaran yang telah dilakukan sebelumnya, yang digunakan untuk menilai baik kemampuan maupun niat peminjam dalam memenuhi kewajiban keuangannya di masa yang akan datang (Çallı & Coşkun, 2021). Informasi ini meliputi ringkasan kondisi keuangan, pemanfaatan jalur kredit, rekam jejak pembayaran, serta perubahan pendapatan individu dari waktu ke waktu. Indikator untuk mengevaluasi variabel ini berdasarkan ketetapan OJK yaitu berupa tingkat kolekbilitas sesuai dengan riwayat pembayaran yang dilakukan oleh peminjam (OJK-WP, 2018; OJK, 2025a).

Dalam teori asimetri informasi, catatan kredit berperan sebagai "sinyal" penting untuk mengurangi ketidakcocokan data antara peminjam dan investor, di mana rekam jejak yang baik membantu mengurangi masalah pemilihan yang merugikan (*adverse selection*) (Çallı & Coşkun, 2021; Vu, 2023). Di sisi lain, teori risiko kredit menganggap perilaku keuangan masa lalu sebagai indikator yang kuat

untuk kinerja kredit di masa mendatang (Bennett et al., 2026; Nigmonov et al., 2024).

Hubungan antara riwayat kredit dan risiko gagal bayar terletak pada peran informasi dari catatan tersebut. Riwayat kredit yang baik secara signifikan mengurangi kebingungan informasi tentang kepatuhan nasabah, sementara riwayat yang buruk menjadi landasan bagi *platform* untuk memprediksi kemungkinan kerugian (Kovrijnykh et al., 2023; Snakkers, 2021). Dapat disimpulakan bahwa riwayat kredit adalah faktor paling penting dalam menentukan kelayakan pinjaman karena menyajikan data objektif yang menggambarkan profil risiko nasabah dengan jelas.

Argumen ini didukung oleh beberapa penelitian, Lee (2020) dan Vu (2023)**,** menemukan bahwa peminjam berulang (*repeat borrowers*) dengan riwayat positif secara signifikan mengurangi ketidakpastian informasi bagi investor. Selain itu, Bennett et al. (2026) dan Muñoz-Cancino et al. (2023)**,** juga mendukung bahwa analisis rekam jejak pembayaran merupakan metode efektif untuk memprediksi probabilitas gagal bayar nasabah secara akurat. Penelitian Sifrain (2023) menemukan bahwa riwayat kredit memiliki pengaruh besar dalam memprediksi risiko gagal bayar pada *platform P2P* lending.

Berdasarkan hubungan antar variabel yang telah dijelaskan, dirumuskan hipotesis sebagai berikut:

H5: Riwayat Kredit memiliki pengaruh terhadap Risiko Gagal Bayar.