

Solusi Penentuan Penerima Kartu dengan Menggunakan Data Mining dalam Industri Perbankan

Iwan Santosa^{1*}, Triuli Novianti²

Department of informatics Engineering, Universitas Trunojoyo¹
Department of Electrical Engineering, Universitas Muhammadiyah Surabaya²
iwan@trunojoyo.ac.id¹, triuli.novianti@ft.um-surabaya.ac.id²

Informasi Artikel

Riwayat Artikel:

Disubmit Mei 31, 2024
Diterima Juni 15, 2024
Diterbitkan Juli 23, 2024

Kata Kunci:

Industri Perbankan
Kartu Kredit
Decision Tree C 4.5

ABSTRAK

Meningkatnya jumlah pemohon kartu kredit di sektor perbankan memerlukan sistem yang efisien untuk menangani proses seleksi. Penelitian ini mengusulkan solusi berbasis data mining dengan menerapkan algoritma Decision Tree C4.5. Data yang digunakan diambil dari situs open data Kaggle, terdiri dari 1.548 entri dengan 11 atribut. Proporsi pembagian data training dan testing bervariasi antara 70%, 75%, 80%, 85%, dan 90%. Hasil menunjukkan akurasi tertinggi sebesar 88,82% dicapai dengan 70% data training. Rata-rata akurasi keseluruhan adalah 87,63%, yang tergolong tinggi. Temuan ini menunjukkan bahwa model tersebut dapat mempercepat proses seleksi dalam pemberian kartu kredit. Implementasi algoritma Decision Tree C4.5 terbukti memberikan solusi yang efisien dan akurat, memungkinkan bank untuk menentukan kelayakan pemohon dengan lebih cepat dan tepat. Penelitian ini mengkonfirmasi efektivitas penerapan data mining dalam menangani lonjakan permohonan kartu kredit, serta menyediakan dasar pengambilan keputusan yang terstruktur dan berbasis data. Model ini sangat direkomendasikan untuk meningkatkan efisiensi proses seleksi dan penentuan kelayakan pemohon kartu kredit di sektor perbankan.

© This work is licensed under a Creative Commons Attribution-ShareAlike 4.0 International License.

*Penulis Korespondensi:

Iwan Santosa
Department of informatics Engineering
Universitas Trunojoyo
Po. Box. 2 Kamal, Bangkalan, Madura
Email: iwan@trunojoyo.ac.id

1. PENDAHULUAN

Penggunaan kartu kredit sebagai salah satu alternatif pembayaran yang mudah dan dapat digunakan secara internasional telah menjadi populer [1]. Namun, banyak pemegang kartu kredit yang memiliki riwayat penggunaan yang tidak sehat, yang dapat mengakibatkan masalah finansial bagi diri mereka sendiri dan pemberi pinjaman [2]. Oleh karena itu, diperlukan sebuah tool atau perangkat yang dapat membantu dalam menentukan apakah seseorang layak memegang tanggung jawab untuk mendapatkan kelayakan memegang kartu kredit.

Dalam era digital saat ini, teknologi telah mempengaruhi hampir semua aspek kehidupan, termasuk dalam bidang keuangan [3]. Salah satu fenomena yang tidak terkecuali adalah penggunaan kartu kredit. Kartu kredit telah menjadi alat pembayaran yang populer dan praktis, memudahkan transaksi sehari-hari [4]. Namun, penggunaan kartu kredit juga membawa tantangan tersendiri, terutama dalam menentukan siapa yang layak menerima kartu kredit. Oleh karena itu, penting bagi

bank dan lembaga keuangan lainnya untuk memiliki sistem yang efektif dalam menentukan kelayakan penerima kartu kredit.

Salah satu metode yang dapat digunakan untuk menentukan kelayakan penerima kartu kredit adalah menggunakan Decision Tree (Pohon Keputusan). Decision Tree adalah algoritma machine learning yang digunakan untuk membuat model prediktif berbasis keputusan [5]. Algoritma ini bekerja dengan cara membagi dataset menjadi beberapa sub-dataset berdasarkan nilai atribut tertentu, sehingga dapat menghasilkan model yang dapat memprediksi kelayakan penerima kartu kredit dengan akurat. Algoritma ini dapat digunakan untuk mengembangkan model yang dapat mengevaluasi data pelanggan dan memprediksi apakah seseorang berpotensi memiliki riwayat penggunaan kartu kredit yang sehat atau tidak. Dengan demikian, tool ini dapat membantu pemberi pinjaman atau lembaga keuangan dalam membuat keputusan yang lebih tepat dalam memberikan atau menolak aplikasi kartu kredit.

Keuntungan utama dari menggunakan Decision Tree adalah kemudahan dalam interpretasi hasilnya [6]. Model yang dihasilkan oleh Decision Tree dapat dijelaskan secara visual, yang memudahkan pemahaman tentang faktor-faktor apa saja yang mempengaruhi kelayakan penerima kartu kredit. Selain itu, Decision Tree juga memiliki keunggulan dalam menangani data yang tidak terstruktur atau data yang memiliki banyak variable [7].

Namun, meskipun Decision Tree memiliki banyak kelebihan, ada juga beberapa tantangan yang perlu dihadapi. Salah satunya adalah overfitting, yaitu kondisi dimana model terlalu kompleks dan cenderung memprediksi data latih dengan baik tetapi kurang efektif dalam memprediksi data baru. Untuk mengatasi masalah ini, beberapa teknik seperti pruning (pemangkasan) pohon dan tuning parameter dapat digunakan.

Studi ini bertujuan untuk menganalisis penggunaan Decision Tree dalam menentukan kelayakan penerima kartu kredit. Melalui penelitian ini, diharapkan dapat ditemukan model yang efektif dan efisien dalam menentukan kelayakan penerima kartu kredit, yang pada akhirnya dapat membantu bank dan lembaga keuangan lainnya dalam mengambil keputusan yang tepat.

Hasil dari penelitian ini diharapkan dapat memberikan wawasan baru tentang bagaimana Decision Tree dapat digunakan dalam konteks keuangan, khususnya dalam menentukan kelayakan penerima kartu kredit. Dengan demikian, penelitian ini diharapkan dapat berkontribusi pada pengembangan sistem keuangan yang lebih baik dan efisien.

2. KAJIAN PUSTAKA

2.1 Kartu Kredit

Kartu kredit telah menjadi bagian integral dari kehidupan sehari-hari, memudahkan transaksi pembayaran dan memungkinkan pembelanjaan dengan kredit [8]. Namun, memberikan kartu kredit kepada individu yang tidak layak atau memiliki potensi risiko tinggi dapat berdampak negatif bagi bank dan sistem keuangan secara keseluruhan [9]. Oleh karena itu, penting bagi bank untuk menerapkan metode yang efektif dalam menentukan kelayakan penerima kartu kredit. Salah satu metode yang dapat digunakan adalah Decision Tree (Pohon Keputusan), sebuah teknik machine learning yang populer dalam bidang kecerdasan buatan dan analisis data [10].

2.2 Data Mining

Data mining adalah proses ekstraksi, penyimpanan, dan analisis data yang besar untuk menghasilkan informasi berharga [11]. Dalam konteks penilaian kelayakan penerima kartu kredit, data mining dapat digunakan untuk mengidentifikasi pola dan hubungan antara berbagai faktor yang mempengaruhi keputusan tersebut. Faktor-faktor ini bisa mencakup usia, pendapatan, riwayat kredit, dan sejarah keuangan lainnya. Dengan menggunakan teknik data mining, bank dapat mengolah dan menganalisis data historis dan demografis dari calon penerima kartu kredit untuk membuat prediksi yang lebih akurat tentang kemungkinan risiko kredit yang akan dihadapi.

2.3 Algoritma Decision Tree

Algoritma Decision Tree adalah salah satu algoritma machine learning yang paling sering digunakan dalam data mining [12]. Algoritma ini menggunakan representasi grafis untuk

menggambarkan hubungan antara variabel input dan output. Dalam konteks penilaian kelayakan penerima kartu kredit, algoritma Decision Tree dapat digunakan untuk mengidentifikasi faktor-faktor penting yang mempengaruhi keputusan tersebut. Keuntungan utama dari penggunaan algoritma Decision Tree dalam penilaian kelayakan penerima kartu kredit adalah kemampuannya untuk menangani dataset yang kompleks dan besar, serta kemudahan dalam interpretasi hasilnya.

Secara keseluruhan, algoritma Decision Tree menawarkan solusi yang cepat dan akurat dalam proses penentuan penerima kartu kredit dalam industri perbankan. Dengan kemampuannya untuk mengidentifikasi pola dan hubungan antara berbagai faktor yang mempengaruhi risiko kredit, algoritma ini dapat membantu bank dalam mengambil keputusan yang lebih baik dan mengurangi risiko kredit yang mungkin timbul. Namun, penting bagi bank untuk memahami keterbatasan dan tantangan ini agar dapat mengoptimalkan penggunaan algoritma Decision Tree dalam operasional mereka.

2.4 RapidMiner

Dalam melakukan proses pengolahan data, disini penulis menggunakan sebuah tools yaitu rapidminer version 9.10. Rapidminer adalah alat penambangan data yang kuat untuk membuat model prediktif dengan cepat [13]. Alat *all-in-one* menampilkan ratusan persiapan data dan algoritma pembelajaran mesin untuk mendukung semua proyek data mining. Program ini memungkinkan pengguna untuk memasukkan data mentah, termasuk database, dan teks, yang kemudian dianalisis secara otomatis dan cerdas dalam skala besar. Rapidminer digunakan untuk penelitian, pendidikan, pelatihan, pembuatan prototipe cepat, pengembangan aplikasi, dan aplikasi industri [14].

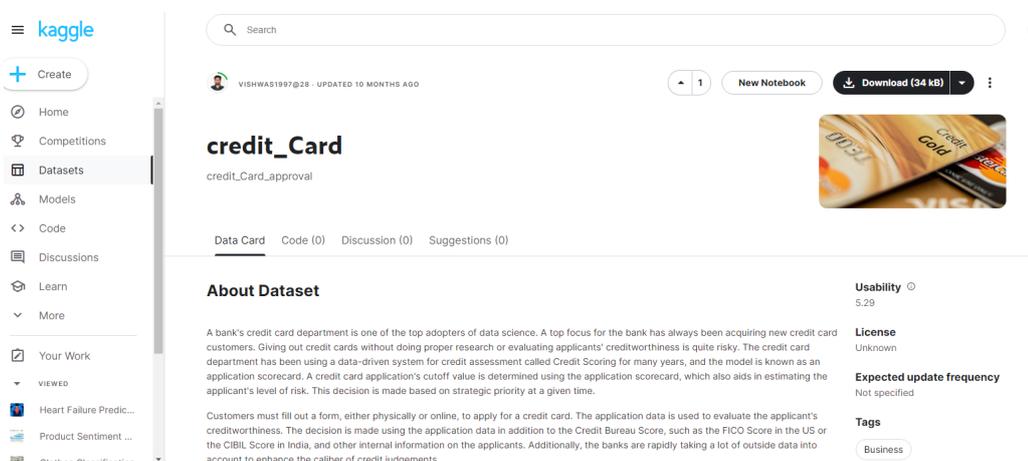
3. METODE PENELITIAN

3.1 Studi Literatur

Pada tahap ini telah dilakukan pencarian referensi dari studi literatur terkait data mining dalam hal ini algoritma decision tree, rapidminer dan kartu kredit. Pencarian informasi juga dilakukan terkait dengan data yang dibutuhkan untuk melakukan penelitian ini melalui website open data. Website ini memberikan informasi dari data-data yang secara bebas dapat kita gunakan untuk melakukan penelitian.

3.2 Pengolahan data

Pada penelitian ini sumber data yang akan digunakan merupakan data sekunder dari yang diambil dari situs web Kaggle <https://www.kaggle.com/datasets/vishwas199728/credit-card>. Situs ini menyediakan data-data open source terkait bidang data science [16], [17]. Data yang didapatkan adalah 1568 record data yang terdiri dari 18 atribut.



The image shows a screenshot of the Kaggle website interface. On the left, there is a navigation menu with options like 'Home', 'Competitions', 'Datasets', 'Models', 'Code', 'Discussions', 'Learn', and 'More'. The main content area displays the 'credit_card' dataset page. The title is 'credit_card' and the subtitle is 'credit_card_approval'. Below the title, there are tabs for 'Data Card', 'Code (0)', 'Discussion (0)', and 'Suggestions (0)'. The 'About Dataset' section contains a detailed description of the dataset, mentioning that it is a bank's credit card department data used for credit scoring. The 'Usability' score is 5.29, and the 'License' is 'Unknown'. There is also a 'Tags' section with a 'Business' tag.

Gambar 1. Koleksi data dari www.kaggle.com

Dari atribut yang relevan digunakan untuk penelitian hanya 11 atribut meliputi jenis kelamin, kepemilikan mobil, kepemilikan rumah, jumlah anak, besar gaji, tipe pedapatan, Pendidikan, status pernikahan, tipe rumah, tipe pekerjaan, jumlah keluarga. Terdapat record yang tidak ada datanya pada attribute tertentu sehingga dihapus record tersebut. Hal ini mengakibatkan jumlah data yang digunakan berkurang menjadi 1548 record.

3.3 Perancangan Rapidminer

Dalam melakukan proses pengolahan data, disini penulis menggunakan sebuah tools yaitu rapidminer version 9.10. Rapidminer adalah alat penambangan data yang kuat untuk membuat model prediktif dengan cepat. Alat all-in-one menampilkan ratusan persiapan data dan algoritma pembelajaran mesin untuk mendukung semua proyek data mining. Program ini memungkinkan pengguna untuk memasukkan data mentah, termasuk database, dan teks, yang kemudian dianalisis secara otomatis dan cerdas dalam skala besar. Rapidminer digunakan untuk penelitian, pendidikan, pelatihan, pembuatan prototipe cepat, pengembangan aplikasi, dan aplikasi industri.

3.4 Analisa

Pada tahap ini telah dilakukan Analisa terhadap hasil dari data yang dimasukkan kedalam model perancangan. Untuk mendapatkan hasil yang benar, pengaturan dalam diagram pada rapidminer dilakukan dengan tepat sehingga tidak menghasilkan kesalahan. Pengaturan tersebut data inputan yang harus sudah ditentukan labelnya, pembagian data training dan data testing serta koneksi antara komponen dalam diagram. Pembagian data training mulai dari 70%,75%,80%,85% dan 90%. Hasil yang didapatkan meliputi *recall*, *precision* dan Akurasi. Dari perubahan prosentase tersebut akan dilihat yang memiliki akurasi tertinggi.

4. HASIL DAN PEMBAHASAN

4.1 Pengolahan data

Pada pengolahan data ini data yang didapatkan akan dilakukan preprocessing data dan merubah tipe data pada aplikasi rapidminer.

4.1.1 Preprocessing Data

Dari data yang didownload pada web seperti yang sudah ditulis pada metode penelitian diatas masih terdapat 18 atribut. Berdasarkan atribut yang penting dan relevan akhirnya hanya 11 atribut yang digunakan pada penelitian ini. Gambar 2 menunjukkan beberapa record hasil pengolahan yang menunjukkan atribut yang akan digunakan dalam proses. Pembersihan data juga dilakukan secara manual untuk mengantisipasi adanya *missing*, *noise* dan *duplicate data*.

Jenis Kelamin	Kepemilikan Mobil	Kepemilikan Rumah	Jumlah anak	Besar Gaji	Tipe Pendapatan	Pendidikan	Status Pernikahan	Tipe Rumah	Tipe Pekerjaan	Jumlah Keluarga	Hasil
F	N	Y	1	rendah sekali	Commercial associate	Higher education	Married	House / apartment	Waiters/barmen staff	3	yes
F	N	N	0	rendah sekali	Working	Secondary / secondary special	Married	House / apartment	Waiters/barmen staff	2	yes
F	N	N	0	rendah sekali	Working	Secondary / secondary special	Civil marriage	House / apartment	Waiters/barmen staff	2	yes
F	Y	Y	0	rendah sekali	Commercial associate	Higher education	Separated	House / apartment	Waiters/barmen staff	1	yes
F	N	Y	0	rendah sekali	Commercial associate	Secondary / secondary special	Married	House / apartment	Waiters/barmen staff	2	yes
F	N	Y	1	sedang	Commercial associate	Secondary / secondary special	Single / not married	House / apartment	Security staff	2	yes
M	N	N	0	rendah sekali	Working	Secondary / secondary special	Widow	Municipal apartment	Security staff	1	yes
M	N	Y	0	rendah sekali	Commercial associate	Higher education	Married	House / apartment	Security staff	2	yes
M	N	Y	0	rendah sekali	Commercial associate	Higher education	Married	House / apartment	Security staff	2	yes
M	N	Y	0	rendah sekali	Commercial associate	Higher education	Married	House / apartment	Security staff	2	yes
F	N	Y	0	rendah sekali	Working	Secondary / secondary special	Married	House / apartment	Security staff	2	yes
M	Y	N	0	rendah sekali	Working	Secondary / secondary special	Married	Office apartment	Security staff	2	yes
M	Y	N	0	rendah sekali	Working	Secondary / secondary special	Married	Office apartment	Security staff	2	yes
F	N	Y	2	rendah sekali	Working	Secondary / secondary special	Married	House / apartment	Security staff	4	yes
F	N	N	0	rendah sekali	Working	Higher education	Married	House / apartment	Security staff	2	yes
M	N	Y	0	rendah sekali	Working	Secondary / secondary special	Single / not married	House / apartment	Security staff	1	yes
M	Y	Y	0	rendah sekali	Working	Higher education	Married	House / apartment	Security staff	2	yes
M	Y	N	0	rendah sekali	Working	Secondary / secondary special	Separated	House / apartment	Security staff	1	yes
M	N	Y	0	rendah sekali	Working	Secondary / secondary special	Civil marriage	House / apartment	Security staff	2	yes
M	N	Y	0	rendah sekali	Working	Secondary / secondary special	Married	House / apartment	Security staff	2	yes
M	Y	N	0	rendah sekali	Working	Secondary / secondary special	Married	House / apartment	Security staff	2	yes
M	N	Y	2	rendah sekali	Working	Secondary / secondary special	Married	House / apartment	Security staff	4	yes
M	N	Y	2	rendah sekali	Working	Secondary / secondary special	Married	House / apartment	Security staff	4	yes
F	N	Y	0	rendah sekali	Commercial associate	Secondary / secondary special	Single / not married	House / apartment	Security staff	1	yes
F	N	Y	0	rendah sekali	Working	Secondary / secondary special	Married	House / apartment	Security staff	2	yes
F	N	N	0	rendah sekali	Working	Secondary / secondary special	Married	House / apartment	Security staff	2	yes
M	Y	Y	0	rendah sekali	Working	Higher education	Married	House / apartment	Security staff	2	yes
M	Y	Y	1	tinggi	Commercial associate	Incomplete higher	Civil marriage	Office apartment	Security staff	3	yes

Gambar 2. Hasil pengolahan data

4.1.2 Format Tipe Data

Pada tahap ini dilakukan perubahan tipe data menyesuaikan dengan data pada record menjadi format tertentu. Gambar 3 menunjukkan data yang sudah dirubah tipe datanya.

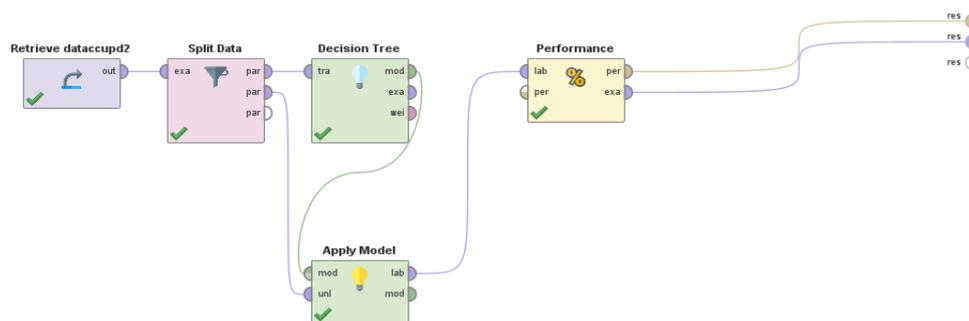
1. Jenis Kelamin = Binomial
2. Kepemilikan Mobil = Binominal
3. Kepemilikan Rumah: Binominal
4. Jumlah anak = Integer
5. Besar gaji = Polinomial
6. Tipe pedapatan = Polynominal
7. Pendidikan = Polynominal
8. Status pernikahan = Polynominal
9. Tipe rumah = Polynominal
10. Tipe pekerjaan = Polynominal
11. Jumlah keluarga. = Integer

	Jenis Kela... <i>binominal</i>	Kepemilika... <i>binominal</i>	Kepemilika... <i>binominal</i>	Jumlah anak <i>integer</i>	Besar Gaji <i>polynominal</i>	Tipe Penda... <i>polynominal</i>	Pendidikan <i>polynominal</i>	Status Peni. <i>polynominal</i>
1	F	N	Y	1	rendah sekali	Commercial ass...	Higher education	Married
2	F	N	N	0	rendah sekali	Working	Secondary / seco...	Married
3	F	N	N	0	rendah sekali	Working	Secondary / seco...	Civil marriage
4	F	Y	Y	0	rendah sekali	Commercial ass...	Higher education	Separated
5	F	N	Y	0	rendah sekali	Commercial ass...	Secondary / seco...	Married
6	F	N	Y	1	sedang	Commercial ass...	Secondary / seco...	Single / not m
7	M	N	N	0	rendah sekali	Working	Secondary / seco...	Widow
8	M	N	Y	0	rendah sekali	Commercial ass...	Higher education	Married
9	M	N	Y	0	rendah sekali	Commercial ass...	Higher education	Married
10	M	N	Y	0	rendah sekali	Commercial ass...	Higher education	Married
11	F	N	Y	0	rendah sekali	Working	Secondary / seco...	Married
12	M	Y	N	0	rendah sekali	Working	Secondary / seco...	Married
13	M	Y	N	0	rendah sekali	Working	Secondary / seco...	Married
14	F	N	Y	2	rendah sekali	Working	Secondary / seco...	Married
15	F	N	N	0	rendah sekali	Working	Higher education	Married
16	M	N	Y	0	rendah sekali	Working	Secondary / seco...	Single / not m
17	M	Y	Y	0	rendah sekali	Working	Higher education	Married
18	M	Y	N	0	rendah sekali	Working	Secondary / seco...	Separated

Gambar 3. Formating Data

4.2 Perancangan

Pada tahap ini dilakukan pemodelan algoritma decision tree C4.5 dengan *criterion gain ratio* pada *data set* kartu kredit yang terdiri dari 11 atribut. Gambar 4 menunjukkan pemodelannya sedangkan gambar 5 adalah model pohon keputusannya.

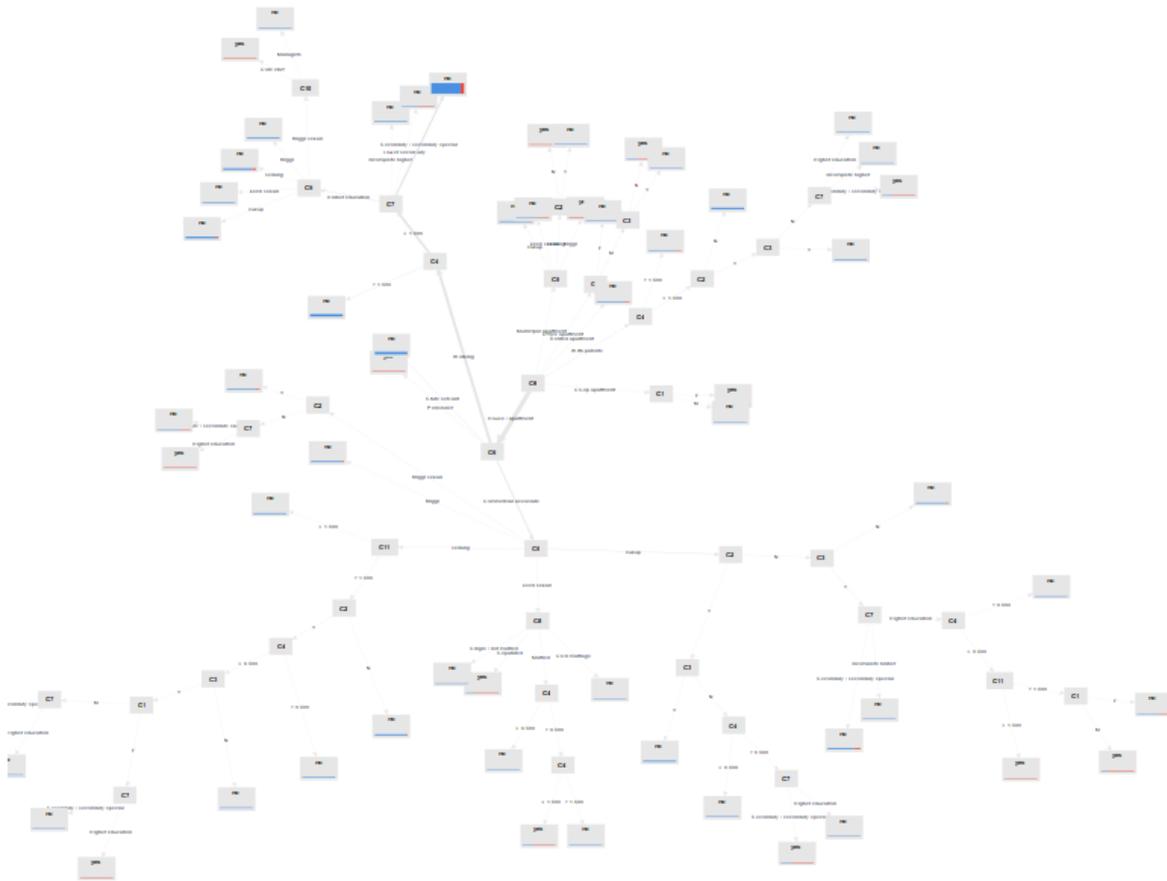


Gambar 4. Perancangan Decision Tree

Data yang sudah melalui *preprocessing* kemudian diinputkan pada perancangan yang sesuai dengan gambar 4. Setelah itu data yang dimasukkan dibagi menjadi data training dan data testing. Data training dan data testing dibuat bervariasi untuk menghasilkan akurasi yang paling optimum.

4.3 Hasil Analisa

Setelah melakukan *running* program dan evaluasi performance akan menghasilkan pohon keputusan seperti gambar dibawah ini. Gambar 5 yang ditampilkan kurang jelas karena atribut dan kriteria yang cukup banyak sehingga perlu ditampilkan rule yang terbentuk untuk memperjelas pohon keputusan tersebut.



Gambar 5. Gambar Tree

Berikut adalah rule yang terbentuk dari perancangan dan pengimputan data yang telah dilakukan. Hal ini menjelaskan secara detail dari *tree* yang terbentuk pada gambar 5 diatas.

```

Tipe Rumah = Co-op apartment
| Jenis Kelamin = F: yes {no=1, yes=2}
| Jenis Kelamin = M: no {no=2, yes=0}
Tipe Rumah = House / apartment
| Tipe Pendapatan = Commercial associate
| | Pendapatan = cukup
| | | Kepemilikan Mobil = N
| | | | Kepemilikan Rumah = N: no {no=14, yes=1}
| | | | Kepemilikan Rumah = Y
| | | | Pendidikan = Higher education
| | | | Jumlah anak > 0.500: no {no=3, yes=0}
| | | | Jumlah anak ≤ 0.500
| | | | Jumlah Keluarga > 1.500
| | | | | Jenis Kelamin = F: no {no=2, yes=1}
| | | | | Jenis Kelamin = M: yes {no=1, yes=4}
| | | | | Jumlah Keluarga ≤ 1.500: yes {no=0, yes=2}
| | | | Pendidikan = Incomplete higher: no {no=3, yes=0}
| | | | Pendidikan = Secondary / secondary special: no {no=21, yes=5}

```

```

| | | Kepemilikan Mobil = Y
| | | Kepemilikan Rumah = N
| | | Jumlah anak > 0.500
| | | Pendidikan = Higher education: no {no=3, yes=0}
| | | Pendidikan = Secondary / secondary special: yes {no=1, yes=2}
| | | Jumlah anak ≤ 0.500: no {no=6, yes=0}
| | | Kepemilikan Rumah = Y: no {no=23, yes=0}
| Pendapatan = kecil sekali
| | Status Pernikahan = Civil marriage: no {no=2, yes=0}
| | Status Pernikahan = Married
| | Jumlah anak > 0.500
| | Jumlah anak > 1.500: no {no=2, yes=0}
| | Jumlah anak ≤ 1.500: yes {no=1, yes=2}
| | Jumlah anak ≤ 0.500: no {no=4, yes=0}
| | Status Pernikahan = Separated: yes {no=1, yes=3}
| | Status Pernikahan = Single / not married: no {no=4, yes=0}
| Pendapatan = sedang
| Jumlah Keluarga > 1.500
| | Kepemilikan Mobil = N: no {no=25, yes=1}
| | Kepemilikan Mobil = Y
| | Jumlah anak > 0.500: no {no=9, yes=0}
| | Jumlah anak ≤ 0.500
| | | Kepemilikan Rumah = N: no {no=6, yes=0}
| | | Kepemilikan Rumah = Y
| | | Jenis Kelamin = F
| | | Pendidikan = Higher education: yes {no=0, yes=2}
| | | Pendidikan = Secondary / secondary special: no {no=2, yes=0}
| | | Jenis Kelamin = M
| | | Pendidikan = Higher education: no {no=4, yes=0}
| | | Pendidikan = Secondary / secondary special: yes {no=1, yes=2}
| | Jumlah Keluarga ≤ 1.500: no {no=15, yes=0}
| Pendapatan = tinggi: no {no=20, yes=1}
| Pendapatan = tinggi sekali
| | Kepemilikan Mobil = N
| | Pendidikan = Higher education: yes {no=0, yes=3}
| | Pendidikan = Secondary / secondary special: no {no=2, yes=1}
| | Kepemilikan Mobil = Y: no {no=11, yes=2}
| Tipe Pendapatan = Pensioner: yes {no=0, yes=3}
| Tipe Pendapatan = State servant: no {no=70, yes=1}
| Tipe Pendapatan = Working
| Jumlah anak > 1.500: no {no=64, yes=1}
| Jumlah anak ≤ 1.500
| | Pendidikan = Higher education
| | Pendapatan = cukup: no {no=41, yes=3}
| | Pendapatan = kecil sekali: no {no=9, yes=0}
| | Pendapatan = sedang: no {no=34, yes=4}
| | Pendapatan = tinggi: no {no=16, yes=0}
| | Pendapatan = tinggi sekali
| | | Tipe Pekerjaan = Core staff: yes {no=0, yes=3}
| | | Tipe Pekerjaan = Managers: no {no=3, yes=0}
| | Pendidikan = Incomplete higher: no {no=13, yes=0}
| | Pendidikan = Lower secondary: no {no=3, yes=3}
| | Pendidikan = Secondary / secondary special: no {no=302, yes=36}
Tipe Rumah = Municipal apartment
| Pendapatan = cukup: no {no=15, yes=1}
| Pendapatan = kecil sekali: no {no=2, yes=1}
| Pendapatan = sedang
| | Kepemilikan Mobil = N: yes {no=0, yes=3}
| | Kepemilikan Mobil = Y: no {no=3, yes=0}
| Pendapatan = tinggi: yes {no=0, yes=3}
Tipe Rumah = Office apartment
| Jenis Kelamin = F: no {no=3, yes=0}
| Jenis Kelamin = M
| | Kepemilikan Rumah = N: yes {no=1, yes=2}
| | Kepemilikan Rumah = Y: no {no=2, yes=0}
Tipe Rumah = Rented apartment: no {no=10, yes=2}

```

```

Tipe Rumah = With parents
| Jumlah anak > 1.500: no {no=4, yes=1}
| Jumlah anak ≤ 1.500
| | Kepemilikan Mobil = N: no {no=36, yes=0}
| | Kepemilikan Mobil = Y
| | | Kepemilikan Rumah = N
| | | | Pendidikan = Higher education: no {no=4, yes=0}
| | | | Pendidikan = Incomplete higher: no {no=2, yes=0}
| | | | Pendidikan = Secondary / secondary special: yes {no=1, yes=2}
| | | Kepemilikan Rumah = Y: no {no=11, yes=0}

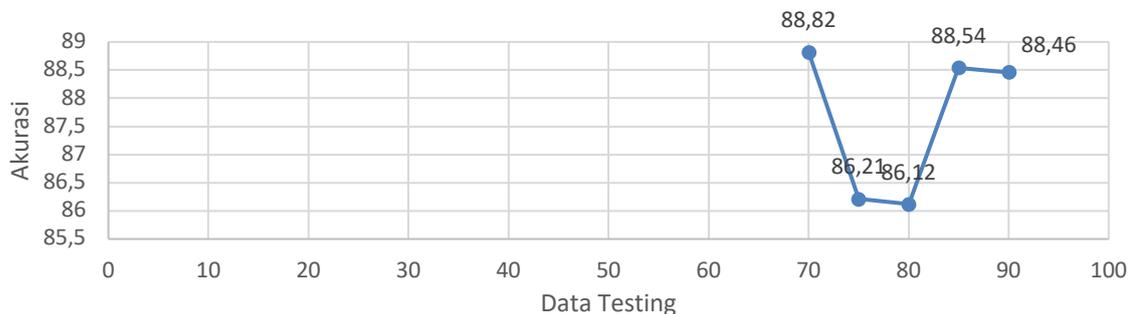
```

Dari pengujian data testing dan data training didapatkan tabel berikut:

Tabel 1. Akurasi dari perubahan *Data Testing* dan *Data Training*

No	Data Training	Data Testing	Recall (TP)	Recall (TN)	Precision (TP)	Precision (TN)	Akurasi
1	70	30	95,85	14,73	90,40	45,45	88,82
2	75	25	94,42	17,86	90,53	27,78	86,21
3	80	20	95,16	13,04	89,85	25,00	86,12
4	85	15	96,43	23,53	91,22	44,44	88,54
5	90	10	95,70	27,27	91,75	42,86	88,46

Dari tabel 1 diatas terlihat bahwa akurasi yang dihasilkan optimum pada data training 70% dan data testing 30% yaitu menghasilkan akurasi 88,82. Jika dirata-rata hasil dari seluruh pengujian didapatkan $438,15/5 = 87,63$. Untuk memudahkan pembacaan dengan visual grafik akurasi ditunjukkan pada gambar 6.



Gambar 6. Grafik Akurasi

5. KESIMPULAN

Penelitian ini telah dilaksanakan menggunakan algoritma data mining Decision Tree C4.5 dengan memanfaatkan tool RapidMiner. Dalam penelitian ini, digunakan sampel sebanyak 1548 data dengan 11 atribut. Persentase data training yang diuji untuk mendapatkan akurasi yang optimal adalah 70%, 75%, 80%, 85%, dan 90%. Hasil menunjukkan bahwa akurasi terbaik dicapai pada data training sebesar 70%, dengan akurasi sebesar 88,82%. Rata-rata akurasi dari semua persentase data training adalah 87,63%, yang masih tergolong baik. Oleh karena itu, model ini direkomendasikan untuk perbankan guna mempermudah proses pemberian kartu kredit kepada nasabah yang berhak, dengan memberikan dasar pengambilan keputusan yang lebih terstruktur dan berbasis data.

DAFTAR PUSTAKA

- [1] T. J. J. Tumbelaka, "TINJAUAN HUKUM TERHADAP JAMINAN KEAMANAN KARTU KREDIT SEBAGAI ALTERNATIF PENGGANTI UANG TUNAI," LEX ADMINISTRATUM, vol. 12, no. 4, 2024.

- [2] N. Ardedia and F. M. Leon, "Faktor–faktor yang mempengaruhi konsumen dalam menggunakan dan berhutang dengan kartu kredit di Jabodetabek," *Jurnal Akuntansi, Keuangan, Dan Manajemen*, vol. 2, no. 2, pp. 83-101, 2021.
- [3] I. A. W. Chrismastianto, "Analisis swot implementasi teknologi finansial terhadap kualitas layanan perbankan di indonesia," *Jurnal Ekonomi dan Bisnis*, vol. 20, no. 1, pp. 133-144, 2017.
- [4] F. N. Khairin, D. A. S. Erawan, and A. Setiawaty, "Edukasi Penggunaan E-Money dan E-Wallet Sebagai Alat Pembayaran Nontunai Pada Era Digital," *Jurnal Mandala Pengabdian Masyarakat*, vol. 4, no. 2, pp. 386-392, 2023.
- [5] R. Darmawan, D. Purnomo, S. Nilawati, and F. Perdiansyah, "Implementasi Algoritma Machine Learning untuk Pengembangan Model Prediktif atas Tingkat Non-Performing Loan dalam rangka Penjaminan Kredit UMKM Pemulihan Ekonomi Nasional," in *SENAKOTA: Seminar Nasional Ekonomi dan Akuntansi*, 2021, vol. 1, no. 1, pp. 97-110.
- [6] A. Prasetio, M. H. Hasibuan, and P. Sitompul, "Simulasi Penerapan Metode Decision Tree (C4. 5) Pada Penentuan Status Gizi Balita," *Jurnal Nasional Komputasi Dan Teknologi Informasi*, vol. 4, no. 3, 2021.
- [7] K. A. Rokhman, B. Berlilana, and P. Arsi, "Perbandingan Metode Support Vector Machine Dan Decision Tree Untuk Analisis Sentimen Review Komentar Pada Aplikasi Transportasi Online," *Journal of Information System Management (JOISM)*, vol. 2, no. 2, pp. 1-7, 2021.
- [8] N. L. P. Handayani and P. F. Soeparan, "Peran Sistem Pembayaran Digital Dalam Revitalisasi UMKM," *Transformasi: Journal of Economics and Business Management*, vol. 1, no. 3, pp. 20-32, 2022.
- [9] A. T. R. C. Yudha et al., *Fintech Syariah: Teori dan Terapan*. Scopindo Media Pustaka, 2020.
- [10] P. B. N. Setio, D. R. S. Saputro, and B. Winarno, "Klasifikasi Dengan Pohon Keputusan Berbasis Algoritme C4. 5," in *PRISMA, Prosiding Seminar Nasional Matematika*, 2020, vol. 3, pp. 64-71.
- [11] R. Lumbantoruan and P. S. J. Kennedy, "Analisis data mining dan warehousing," *Buletin Ekonomi*, vol. 19, no. 1, pp. 66-76, 2015.
- [12] S. Febriani and H. Sulistiani, "Analisis Data Hasil Diagnosa Untuk Klasifikasi Gangguan Kepribadian Menggunakan Algoritma C4. 5," *Jurnal Teknologi Dan Sistem Informasi*, vol. 2, no. 4, pp. 89-95, 2021.
- [13] R. Nofitri and N. Irawati, "Analisis Data Hasil Keuntungan Menggunakan Software Rapidminer," *JURTEKSI (Jurnal Teknologi dan Sistem Informasi)*, vol. 5, no. 2, pp. 199-204, 2019.
- [14] D. Jollyta, M. Siddik, H. Mawengkang, and S. Efendi, *Teknik Evaluasi Cluster Solusi Menggunakan Python Dan Rapidminer*. Deepublish, 2021.