



**Tugas Akhir – TI 141501**

**PENENTUAN KEPUTUSAN DAN STRATEGI OPTIMAL UNTUK  
MEMINIMASI RISIKO KREDIT MACET DENGAN METODE *DATA  
MINING* DAN *INSPECTION GAME***

ORYZA AKBAR ROCHMADHAN

NRP. 2513100057

Dosen Pembimbing

Prof. Ir. Budi Santosa, M.Sc., Ph.D.

NIP. 196905121994021001

Ko-Dosen Pembimbing

Dr. Eng. Erwin Widodo, S.T., M. Eng.

NIP. 197405171999031002

DEPARTEMEN TEKNIK INDUSTRI

Fakultas Teknologi Industri

Institut Teknologi Sepuluh Nopember

Surabaya 2017

*Halaman ini sengaja dikosongkan*



**Final Project – TI 141501**

**DETERMINING OPTIMUM DECISION AND STRATEGY IN ORDER TO  
MINIMIZE THE RISK OF BAD DEBT BY USING DATA MINING AND  
INSPECTION GAME**

ORYZA AKBAR ROCHMADHAN

NRP. 2513100057

Supervisor

Prof. Ir. Budi Santosa, M.Sc., Ph.D.

NIP. 196905121994021001

Co-Supervisor

Dr. Eng. Erwin Widodo, S.T., M. Eng.

NIP. 197405171999031002

DEPARTEMENT OF INDUSTRIAL ENGINEERING

Faculty of Industrial Technology

Institut Teknologi Sepuluh Nopember

Surabaya 2017

*Halaman ini sengaja dikosongkan*

## **LEMBAR PENGESAHAN**

### **PENENTUAN KEPUTUSAN DAN STRATEGI OPTIMAL UNTUK MEMINIMASI RISIKO KREDIT MACET DENGAN METODE *DATA MINING* DAN *INSPECTION GAME***

#### **TUGAS AKHIR**

Diajukan untuk Memenuhi Salah Satu Syarat Memperoleh Gelar Sarjana Teknik

Program Studi S-1 Departemen Teknik Industri

Fakultas Teknologi Industri

Institut Teknologi Sepuluh Nopember

Surabaya

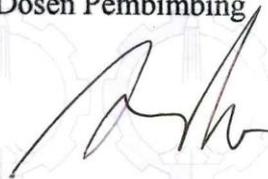
Penulis:

**ORYZA AKBAR ROCHMADHAN**

**NRP. 2513 100 057**

Mengetahui dan menyetujui,

Dosen Pembimbing



**Prof. Ir. Budi Santosa, M.Sc., Ph.D.**

**NIP. 196905121994021001**

Dosen Ko-Pembimbing



**Dr. Eng. Erwin Widodo, S.T., M.Eng.**

**NIP. 197405171999031002**

**SURABAYA, JULI 2017**



*Halaman ini sengaja dikosongkan*

**PENENTUAN KEPUTUSAN DAN STRATEGI OPTIMAL UNTUK  
MEMINIMASI RISIKO KREDIT MACET DENGAN METODE *DATA  
MINING* DAN *INSPECTION GAME***

Nama : Oryza Akbar Rochmadhan  
NRP : 2513100057  
Pembimbing : Prof. Ir. Budi Santosa, M.Sc., Ph.D  
Ko-Pembimbing : Dr. Eng. Erwin Widodo, S.T., M. Eng.

**ABSTRAK**

Kredit macet merupakan salah satu masalah besar yang paling sering dihadapi oleh Bank. Kerugian yang dialami bank dikarenakan permasalahan ini terhitung besar. Keadaan yang dihadapi sekarang, proporsi jumlah kredit lancar berada pada tingkat 83,99%. Pihak Bank berupaya untuk menaikkan proporsi jumlah kredit lancar hingga 95% dengan cara menekan jumlah kredit macet. Dalam penelitian ini, digunakan penerapan *data mining* dan *game theory* dalam menyusun model *decision tree* dan *inspection game* untuk dapat menghasilkan suatu kebijakan yang dapat menekan jumlah kredit macet. Model *decision tree* digunakan untuk mendapat metode prediksi status nasabah selama peminjaman, sedangkan model *inspection game* digunakan untuk mendapatkan kebijakan yang dapat menurunkan tendensi nasabah untuk melakukan kredit macet. Hasil dari penelitian adalah, tingkat akurasi prediksi dari model *decision tree*: nilai POD sebesar 99,50%, TNR sebesar 100%, dan OA sebesar 99,80%. Model *inspection game* merumuskan kebijakan yang dapat menurunkan tendensi nasabah untuk melakukan kredit macet adalah peningkatan suku bunga dan lama waktu tenor.

**Kata Kunci:** *Decision Tree*, *Inspection Game*, Kebijakan, Kredit Macet

*Halaman ini sengaja dikosongkan*

***DETERMINING OPTIMUM DECISION AND STRATEGY IN ORDER TO  
MINIMIZE THE RISK OF BAD DEBT BY USING DATA MINING AND  
INSPECTION GAME***

*Name* : Oryza Akbar Rochmadhan  
*NRP* : 2513100057  
*Supervisor* : Prof. Ir. Budi Santosa, M.Sc., Ph.D  
*Co-Supervisor* : Dr. Eng. Erwin Widodo, S.T., M. Eng

***ABSTRACT***

*Bad debt is one of many big problems which is frequently experienced by Bank X. The loss which is caused by bad debt is considered big. The existing condition, is only 83,99% debt that given by bank is considered as a good debt. Bank X is trying to raise the proportion to 95% by surppressing the bad debt. This research will use data mining and game theory as methods for constructing decision tree model and inspection game that will results in having policy/ies that will surppress bad debt proportion. The decision tree model is used to get prediction method of customers's states during the tenor period, while inspection game model is used to build policy/ies that will reduce the likeliness of customers doing bad debt. The results of this research are, the accuracy of prediction from decision tree model: the value of POD, TNR, and OA are 99,50%, 100%, and 99,80% respectively, the policy/ies from inspection game model that will reduce the likeliness of customers to do bad debt are increasing the loan rate and the tenor period.*

***Keywords:*** *Bad Debt, Decision Tree, Inspection Game, Policy*

*Halaman ini sengaja dikosongkan*

## KATA PENGANTAR

*Alhamdulillah* Allah SWT atas limpahan rahmat dan hidayah-Nya, tidak lupa shalawat serta salam senantiasa tersampaikan pada junjungan Nabi Besar Muhammad SAW sehingga penulis mampu menyelesaikan Tugas Akhir yang berjudul **“Penentuan Keputusan dan Strategi Optimal untuk Meminimasi Risiko Kredit Macet dengan Metode Data Mining dan Inspection Game”**.

Laporan Tugas Akhir ini disusun untuk memenuhi persyaratan menyelesaikan studi Strata-1 (S1) dan memperoleh gelar Sarjana Teknik Industri di Jurusan Teknik Industri, Fakultas Teknologi Industri, Institut Teknologi Sepuluh Nopember Surabaya. Selama proses pengerjaan Tugas Akhir, penulis telah menerima banyak dukungan, masukan, serta bantuan dari berbagai pihak. Pada kesempatan ini, penulis ingin mengucapkan terima kasih kepada:

1. Kedua orang tua penulis, yaitu Bapak Wahyudiono dan Ibu Sri Andayani yang selalu memberikan doa, motivasi, bantuan, dan dukungan yang tidak terhingga kepada penulis.
2. Bapak Prof. Ir. Budi Santosa, M.Sc., Ph.D dan Bapak Dr. Eng. Erwin Widodo, S.T., M.Eng. selaku Dosen Pembimbing serta Dosen Ko-Pembimbing yang telah memberikan semangat, motivasi, arahan, kritik dan saran, serta pembelajaran kehidupan kepada penulis dalam menyelesaikan tugas akhir ini.
3. Ibu Ika yang telah banyak membantu dan memberikan kemudahan bagi penulis dalam pengumpulan data.
4. Ibu Selvia Latuconsina yang telah banyak membantu dan memberikan kemudahan bagi penulis dalam pengumpulan data serta menjadi mentor selama pengerjaan Tugas Akhir.
5. Bapak Stefanus Eko Wiratno, S.T., M.T., Ibu Effi Latiffianti, S.T., M.Sc., dan Ibu Diesta Iva Maftuhah S.T., M.T., selaku dosen penguji saat seminar proposal dan sidang Tugas Akhir yang memberikan kritik serta saran untuk kemajuan Tugas Akhir.

6. Ketua Jurusan Teknik Industri Institut Teknologi Sepuluh Nopember Surabaya, Bapak Nurhadi Siswanto, S.T., M.S.I.E., Ph.D.
7. Bapak Dr. Adithya Sudiarmo, S.T., M.T. selaku Koordinator Tugas Akhir atas kelancaran selama proses penyusunan tugas akhir.

Serta berbagai pihak yang tidak dapat penulis sebut satu persatu oleh penulis, terima kasih atas semua doa, dukungan, nasihat, dan semangat yang diberikan kepada penulis, semoga Allah SWT membalas semua kebaikan tersebut. *Āmīn*.

Penulis menyadari bahwa pengerjaan Tugas Akhir ini masih jauh dari sempurna. Kritik dan saran sangat penulis butuhkan untuk perbaikan kedepannya. Penulis berharap Tugas Akhir ini dapat memberikan manfaat bagi para pembacanya. Sekian yang dapat penulis sampaikan, akhir kata penulis menyampaikan terima kasih.

Surabaya, Juli 2017

Oryza Akbar Rochmadhan

## DAFTAR ISI

<b>LEMBAR PENGESAHAN .....</b>	<b>i</b>
<b>ABSTRAK .....</b>	<b>iii</b>
<b>KATA PENGANTAR.....</b>	<b>vii</b>
<b>DAFTAR ISI.....</b>	<b>ix</b>
<b>DAFTAR TABEL .....</b>	<b>xi</b>
<b>DAFTAR GAMBAR.....</b>	<b>xiii</b>
<b>BAB 1 PENDAHULUAN .....</b>	<b>1</b>
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	3
1.3 Tujuan Penelitian.....	4
1.4 Manfaat Penelitian.....	4
1.5 Ruang Lingkup Penelitian .....	4
1.5.1 Batasan .....	4
1.5.2 Asumsi .....	4
1.6 Sistematika Penulisan.....	5
<b>BAB 2 TINJAUAN PUSTAKA.....</b>	<b>7</b>
1.1 <i>5C Principle</i> .....	7
1.2 <i>Data Mining</i> .....	8
1.3 <i>Decision Tree</i> .....	12
1.4 Model Evaluasi Akurasi .....	16
1.5 <i>Game Theory</i> .....	17
1.5.1 Jenis Games pada Game Theory .....	18
1.5.2 Payoff dalam Game Theory .....	18
2.6 <i>Inspection Game</i> .....	19
2.7 Dasar Hukum.....	20

2.7.1	Undang-Undang Republik Indonesia No.10 Tahun 1998 .....	20
2.7.2	Peraturan Bank Indonesia Nomor 17/10/PBI/ .....	23
<b>BAB 3 METODOLOGI PENYELESAIAN MASALAH .....</b>		<b>27</b>
3.1	Alur Penyelesaian Masalah.....	27
3.2	Tahap Persiapan .....	28
3.3	Tahap Pembuatan Model .....	32
3.3.1	Penyusunan Model Decision Tree .....	32
3.3.2	Penyusunan Model Inspection Game .....	70
3.4	Tahap Hasil dan Analisis Model.....	86
3.5	Tahap Kesimpulan dan Saran .....	86
<b>BAB 4 HASIL DAN ANALISIS .....</b>		<b>87</b>
4.1	Hasil Model.....	87
4.1.1	Hasil Decision Tree .....	87
4.1.2	Metode Pengambilan Keputusan .....	92
4.1.3	Hasil Inspection Game.....	92
4.2	Analisis Model .....	95
4.2.1	Analisis Decision Tree.....	95
4.2.2	Analisis Model Inspection Game .....	96
4.2.3	Analisis Model Keseluruhan .....	97
<b>BAB 5 KESIMPULAN DAN SARAN .....</b>		<b>99</b>
5.1	Kesimpulan .....	99
5.2	Saran .....	99
<b>DAFTAR PUSTAKA .....</b>		<b>101</b>
<b>LAMPIRAN A .....</b>		<b>103</b>
<b>LAMPIRAN B .....</b>		<b>104</b>
<b>LAMPIRAN C .....</b>		<b>106</b>
<b>BIODATA PENULIS .....</b>		<b>111</b>

## DAFTAR TABEL

Tabel 2.1 Matriks Konfusius untuk Klasifikasi Dua Kelas .....	16
Tabel 2. 2 Model <i>Inspection Game</i> .....	19
Tabel 3.1 Variabel Penelitian.....	30
Tabel 3.2 Proporsi Kejadian Lancar-Macet .....	35
Tabel 3.3 <i>Goodness of Split</i> Pemilah x1 .....	36
Tabel 3.4 <i>Goodness of Split</i> Pemilah x2 .....	37
Tabel 3.5 <i>Goodness of Split</i> Pemilah x3 .....	37
Tabel 3.6 <i>Goodness of Split</i> Pemilah x4 .....	37
Tabel 3.7 <i>Goodness of Split</i> Pemilah x5 .....	38
Tabel 3.8 <i>Goodness of Split</i> Pemilah x6 .....	38
Tabel 3.9 <i>Goodness of Split</i> Pemilah x6 (lanjutan).....	38
Tabel 3.10 Nilai <i>Goodness of Split</i> .....	38
Tabel 3.11 <i>Goodness of Split</i> Kelompok Kiri Pemilah x1 .....	40
Tabel 3.12 <i>Goodness of Split</i> Kelompok Kiri Pemilah x3 .....	40
Tabel 3.13 <i>Goodness of Split</i> Kelompok Kiri Pemilah x4.....	41
Tabel 3.14 <i>Goodness of Split</i> Kelompok Kiri Pemilah x5 .....	41
Tabel 3.15 <i>Goodness of Split</i> Kelompok Kiri Pemilah x6.....	41
Tabel 3.16 <i>Goodness of Split</i> Kelompok Kiri Pemilah x6 (lanjutan) .....	41
Tabel 3.17 Nilai <i>Goodness of Split</i> .....	42
Tabel 3.18 Hasil Prediksi <i>Tree75</i> untuk Data <i>Testing</i> .....	59
Tabel 3.19 Hasil Prediksi <i>Tree75</i> untuk Data <i>Training</i> .....	60
Tabel 3.20 Hasil Prediksi <i>Tree80</i> untuk Data <i>Testing</i> .....	61
Tabel 3.21 Hasil Prediksi <i>Tree80</i> untuk Data <i>Training</i> .....	62
Tabel 3.22 Hasil Prediksi <i>Tree85</i> untuk Data <i>Testing</i> .....	63
Tabel 3.23 Hasil Prediksi <i>Tree85</i> untuk Data <i>Training</i> .....	64
Tabel 3.24 Hasil Prediksi <i>Tree90</i> untuk Data <i>Testing</i> .....	65
Tabel 3.25 Hasil Prediksi <i>Tree90</i> untuk Data <i>Training</i> .....	66
Tabel 3.26 Hasil Prediksi <i>Tree95</i> untuk Data <i>Testing</i> .....	67
Tabel 3.27 Hasil Prediksi <i>Tree95</i> untuk Data <i>Training</i> .....	68

Tabel 3.28 Hasil Evaluasi Model <i>Decision Tree</i> .....	69
Tabel 3.29 Model Konseptual <i>Inspection Game</i> Persoalan Kredit Macet .....	71
Tabel 3.30 Model <i>Inspection Game</i> Persoalan Kredit Macet.....	81
Tabel 4.1 Hasil <i>Prunning Decision Tree</i> .....	87

## DAFTAR GAMBAR

Gambar 2.1 Tahapan <i>Knowledge Discovery from Database</i> .....	9
Gambar 2.2 Contoh Model <i>Supervised Learning</i> .....	12
Gambar 2.3 Contoh <i>Classification Tree</i> .....	13
Gambar 3.1 <i>Flowchart</i> Penyelesaian Masalah.....	27
Gambar 3.3 Model <i>Decision Tree</i> 75% .....	46
Gambar 3.4 Model <i>Decision Tree</i> 80% .....	49
Gambar 3.5 Model <i>Decision Tree</i> 85% .....	52
Gambar 3.6 Model <i>Decision Tree</i> 90% .....	55
Gambar 3.7 Model <i>Decision Tree</i> 95% .....	58
Gambar 3.9 <i>Influence Diagram Payoff</i> untuk Bank .....	73
Gambar 4.1 <i>Decision Tree</i> Optimal .....	91
Gambar 4.2 Sensitivitas Denda.....	94
Gambar 4.3 Sensitivitas Tenor.....	94
Gambar 4.4 Sensitivitas <i>Cashback</i> .....	94
Gambar 4.5 Sensitivitas Suku Bunga.....	95

*Halaman ini sengaja dikosongkan*

# **BAB 1**

## **PENDAHULUAN**

Bab ini menjelaskan hal-hal yang mendasari dilakukannya penelitian serta identifikasi masalah penelitian yang meliputi latar belakang, perumusan masalah, tujuan penelitian, manfaat penelitian, batasan dan asumsi yang digunakan, serta sistematika penulisan.

### **1.1 Latar Belakang**

Selama lima tahun terakhir, pengajuan kredit di Indonesia mengalami peningkatan. Data dari Bank Indonesia menunjukkan bahwa pengajuan kredit UMKM mengalami kenaikan rata-rata sebesar 12,25% setiap tahunnya sedangkan untuk kredit non UMKM mengalami kenaikan rata-rata sebesar 10,87% setiap tahunnya. Survei lain yang dilakukan Bank Indonesia memperoleh data mengenai optimisme pertumbuhan kredit non UMKM yaitu kredit konsumsi menunjukkan bahwa Kredit Pemilikan Rumah (KPR) mengalami rata-rata kenaikan sebesar 12,57%, kendaraan bermotor 8,79%, kartu kredit 23,67%, dan kredit tanpa agunan 14,57% untuk tiap tahunnya. Kecenderungan angka yang selalu naik menggambarkan prospek yang baik bagi perusahaan penyedia layanan kredit, khususnya bank.

Peningkatan jumlah permintaan kredit yang terjadi menunjukkan adanya peluang atau kesempatan bagi pelaku-pelaku usaha penyedia layanan kredit. Kesempatan yang muncul harus diiringi dengan strategi yang baik agar dapat memaksimalkan kesempatan yang ada (Sadler & Eugene, 2010). Strategi yang dimaksud adalah kebijakan pengambilan keputusan tentang persetujuan pengajuan kredit. Mekanisme pengambilan keputusan yang buruk dapat mengakibatkan kerugian bagi perusahaan. Kesalahan pengambilan keputusan dapat menyetujui proposal yang berpotensi macet atau menolak proposal yang memiliki prospek yang baik.

Perusahaan penyedia layanan kredit banyak menggunakan metode *credit scoring* dalam penentuan pengambilan keputusan persetujuan pengajuan kredit. *Credit scoring* merupakan suatu metode evaluasi risiko kredit yang ada pada pengajuan kredit berdasarkan atribut-atribut tertentu yang dimiliki oleh nasabah. Metode ini menggunakan teknik-teknik statistik dan data historis yang ada. Metode *credit scoring* melakukan deteksi karakteristik serta perilaku debitur yang berpotensi menyebabkan pembayaran angsuran kredit yang diajukan tidak sesuai dengan tenggat waktu yang telah disepakati atau mengakibatkan kolektabilitas buruk (Kasmir, 2012). Terlepas dari fitur yang dimiliki *credit scoring*, metode ini masih memiliki kekurangan berupa tingkat keakuratan sistem *scoring* dalam mengevaluasi kelompok tertentu. Keakuratan merupakan pertimbangan yang sangat penting dalam penggunaan *credit scoring*. Tingkat akurasi yang belum sempurna disebabkan oleh penyusunan model *scoring* yang tidak akurat. Pemberi pinjaman (bank) dapat menyesuaikan model yang ingin dibuat dengan mengevaluasi biaya-biaya yang dibutuhkan dalam penyusunan model dengan menggunakan *scoring* sehingga jika model tidak akurat, penghematan biaya dapat diraih meskipun *error* pinjaman buruk. Keakuratan sebuah sistem *credit scoring* akan bergantung pada seberapa hati-hati sistem tersebut dikembangkan (Kusuma, 2009). Data yang dibutuhkan dalam sistem ini adalah pelaksanaan pinjaman yang baik dan pelaksanaan pinjaman yang buruk. Data tersebut seharusnya *up to date* dan model-model yang dibangun dapat memperkirakan kembali secara berkelanjutan untuk memastikan perubahan-perubahan dalam hubungan faktor-faktor potensial dan *error* pinjaman yang terjadi.

Permasalahan yang dihadapi oleh Bank X mengenai pengajuan kredit terjadi pada jenis Kredit Pemilikan Rumah (KPR). Data bulan Juli hingga Desember 2016 menunjukkan jumlah nasabah yang mengajukan KPR menunjukkan kecenderungan meningkat. Permintaan peningkatan mengalami kenaikan dengan rata-rata sebesar 9,36%. Permohonan paling sedikit terjadi pada bulan Juli yakni 123 debitur dan paling banyak terjadi pada bulan November yakni 195 debitur. Informasi yang didapatkan dari perusahaan mengungkapkan bahwa hal ini tidak sebanding dengan jumlah analis kredit yang ada di Bank X. Analis kredit yang hanya berjumlah lima orang hanya mampu mengevaluasi 15-20 permohonan

kredit tiap minggunya. Metode *credit scoring* yang digunakan memang membutuhkan waktu (*time consuming*). Sehingga tak jarang debitur memberi umpan balik berupa kekecewaan mengenai lamanya kepastian persetujuan proposal pengajuannya. Permasalahan lain yang terjadi di Bank X adalah mengenai tingkat kolektabilitas kredit yang diberikan. Data bulan Juli-Desember 2016, sebanyak 912 debitur KPR telah didapatkan. Dari jumlah tersebut, hanya 90% menunjukkan kolektabilitas yang baik. Kondisi kolektabilitas kredit yang tidak maksimal menyebabkan Bank X harus mengeluarkan biaya lebih untuk mengumpulkan angsuran yang harus dibayarkan oleh debitur secara langsung. Dampak lain yang disebabkan oleh macetnya kredit yang diberikan adalah *time value* dari suku bunga yang harusnya didapatkan oleh pihak bank apabila debitur membayar tepat waktu. Menanggapi hal tersebut, Bank X menetapkan target kolektabilitas kredit sebesar 95%.

Penyelesaian permasalahan mengenai metode pengambilan keputusan persetujuan permohonan kredit dapat menggunakan konsep *data mining* dengan metode *Classification and Regression Trees* (CART). CART merupakan sebuah metode yang digunakan untuk mempelajari hubungan antara *dependent variable* dan sebuah seri *predictor variable*. Metode ini memiliki tingkat akurasi yang tinggi (Zhang & Hardle, 2008). Kelebihan lain dari metode ini adalah kemampuan untuk menjelaskan hasil atau *result* yang didapat. Sedang untuk permasalahan kredit macet atau kolektabilitas kredit yang tidak maksimal dapat menggunakan aplikasi *game theory*. Aplikasi *game theory* diharapkan mampu memberikan strategi yang dapat mengakomodasi atau mendekatkan pihak bank dengan debitur sehingga kredit macet dapat dihindari. Hal ini dikarenakan *game theory* mempertimbangkan kepentingan masing-masing pihak sehingga diharapkan dapat menghasilkan solusi yang memuaskan kedua belah pihak (*win-win solution*) (Winston, 2003).

## 1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, maka permasalahan yang akan dibahas pada penelitian tugas akhir ini adalah bagaimana menentukan metode pengambilan keputusan persetujuan dari permohonan kredit menggunakan konsep *data mining*

dan bagaimana menentukan strategi yang dapat meminimasi terjadinya kredit macet.

### **1.3 Tujuan Penelitian**

Tujuan penelitian yang ingin dicapai dalam tugas akhir ini adalah sebagai berikut.

1. Meminimasi kesalahan prediksi mengenai kelayakan peminjam kredit.
2. Meningkatkan kolektabilitas kredit yang telah diberikan.

### **1.4 Manfaat Penelitian**

Adapun manfaat yang akan diperoleh dari pelaksanaan penelitian tugas akhir adalah sebagai berikut.

1. Dapat memberikan metode analisis persetujuan yang cepat dan akurat.
2. Dapat mengurangi risiko terjadi kredit macet.
3. Nasabah mendapatkan layanan yang lebih memuaskan.

### **1.5 Ruang Lingkup Penelitian**

Ruang lingkup penelitian tugas akhir terdiri dari dua, yaitu batasan dan asumsi yang digunakan dalam melakukan penelitian tugas akhir. Berikut merupakan batasan dan asumsi penelitian tugas akhir.

#### *1.5.1 Batasan*

Berikut merupakan batasan yang dilakukan dalam penelitian tugas akhir.

1. Data pengajuan kredit yang digunakan adalah Kredit Pemilikan Rumah (KPR) di Surabaya.
2. Data historis yang digunakan adalah data yang diperoleh pada bulan Juli hingga Desember 2016

#### *1.5.2 Asumsi*

Asumsi yang digunakan dalam penelitian tugas akhir adalah data yang didapat telah merepresentasikan kondisi nasabah.

## **1.6 Sistematika Penulisan**

Laporan tugas akhir ini terdiri dari lima bab dengan sistematika penulisan sebagai berikut:

### **BAB 1 PENDAHULUAN**

Pada bab pendahuluan akan dijelaskan mengenai hal-hal yang mendasari dilakukannya penelitian dan identifikasi masalah penelitian. Bahasan yang terdapat pada bab pendahuluan ini meliputi latar belakang masalah, perumusan masalah, ruang lingkup penelitian, tujuan penelitian, manfaat penelitian, serta sistematika penulisan.

### **BAB 2 TINJAUAN PUSTAKA**

Tinjauan pustaka menguraikan teori, temuan, dan bahan penelitian lain yang diperoleh dari acuan yang akan dijadikan landasan untuk melakukan kegiatan penelitian yang akan dijadikan tugas akhir. Pada bab tinjauan pustaka akan dijelaskan mengenai *5C Principle*, *data mining*, *decision tree*, dan model evaluasi akurasi.

### **BAB 3 METODOLOGI PENYELESAIAN MASALAH**

Bab ini menguraikan metodologi penyelesaian masalah yang dilakukan untuk menyelesaikan permasalahan metode pengambilan keputusan mengenai persetujuan pengajuan Kredit Pemilikan Rumah (KPR) Bank X dengan menggunakan *Classification and Regression Trees (CART)* dan aplikasi *game theory*.

### **BAB 4 ANALISIS DAN INTERPRETASI**

Bab ini meliputi serangkaian analisis model-model *decison tree* dan model *inspection game* yang telah dibuat serta penarikan suatu interpretasi mengenai tingkat akurasi yang dihasilkan oleh tiap model yang dibuat.

## **BAB 5 KESIMPULAN DAN SARAN**

Bab ini berisi tentang kesimpulan hasil penelitian dan saran-saran yang berkaitan dengan penelitian selanjutnya.

## **BAB 2**

### **TINJAUAN PUSTAKA**

Bab ini menjelaskan mengenai tinjauan pustaka yang digunakan sebagai pedoman dalam pelaksanaan penelitian tugas akhir. Adapun teori-teori yang akan digunakan untuk mendukung penelitian tugas akhir ini adalah teori-teori yang bersifat umum sampai dengan teori-teori yang bersifat spesifik. Teori-teori yang menjadi landasan penelitian ini adalah *5C Principle*, *data mining*, *decision tree*, metode evaluasi akurasi, dan *game theory*.

#### **1.1 5C Principle**

Proses penyeleksian pengajuan lamaran kredit memiliki acuan prinsip yang harus diperiksa secara menyeluruh dan dipastikan baik agar pihak pemberi pinjaman mendapatkan gambaran mengenai peminjam (Kasmir, 2012). Selain itu, hal ini bertujuan agar proses berjalan dengan baik dan minim risiko. Prinsip tersebut memiliki sebutan 5 C, yaitu sebagai berikut :

- ***Character*** (kepribadian/watak)  
Pihak pemberi pinjaman dapat melakukan evaluasi terhadap debitur, dengan menilai latar belakang pribadi maupun latar belakang pekerjaan. Kriteria yang dapat dinilai adalah: sifat, watak, gaya hidup, hobi, keadaan keluarga, serta kecenderungan perilaku. *Character* merupakan ukuran kemauan nasabah untuk membayar kredit.
- ***Capacity*** (kemampuan)  
Nasabah yang mengajukan pinjaman tentunya memiliki sumber-sumber pendapatan yang akan digunakan untuk membayar kredit. Pihak pemberi pinjaman akan menilai debitur dalam membayar pinjaman berdasarkan kemampuannya mengelola bisnis serta kemampuan mencari laba untuk dijadikan sumber pendapatan. Semakin besar sumber pendapatan, semakin besar kemampuan untuk membayar kredit.
- ***Capital*** (modal)  
Debitur tidak pernah memberi pinjaman modal 100% untuk nasabah, oleh karena itu pihak peminjaman memiliki sumber pembiayaan lain. *Capital*

digunakan untuk mengetahui sumber-sumber pembiayaan yang dimiliki nasabah.

- ***Collateral*** (jaminan)

Merupakan jaminan yang diberikan calon debitur baik dalam bentuk fisik maupun nonfisik. Nilai appraisal dari jaminan sebaiknya lebih besar dari nilai kredit yang dipinjamkan. Status keabsahan jaminan juga telah harus diteliti agar jika terjadi suatu masalah, jaminan dapat digunakan secepat mungkin. Fungsi jaminan adalah sebagai mitigasi risiko kerugian yang dapat dialami oleh kreditur.

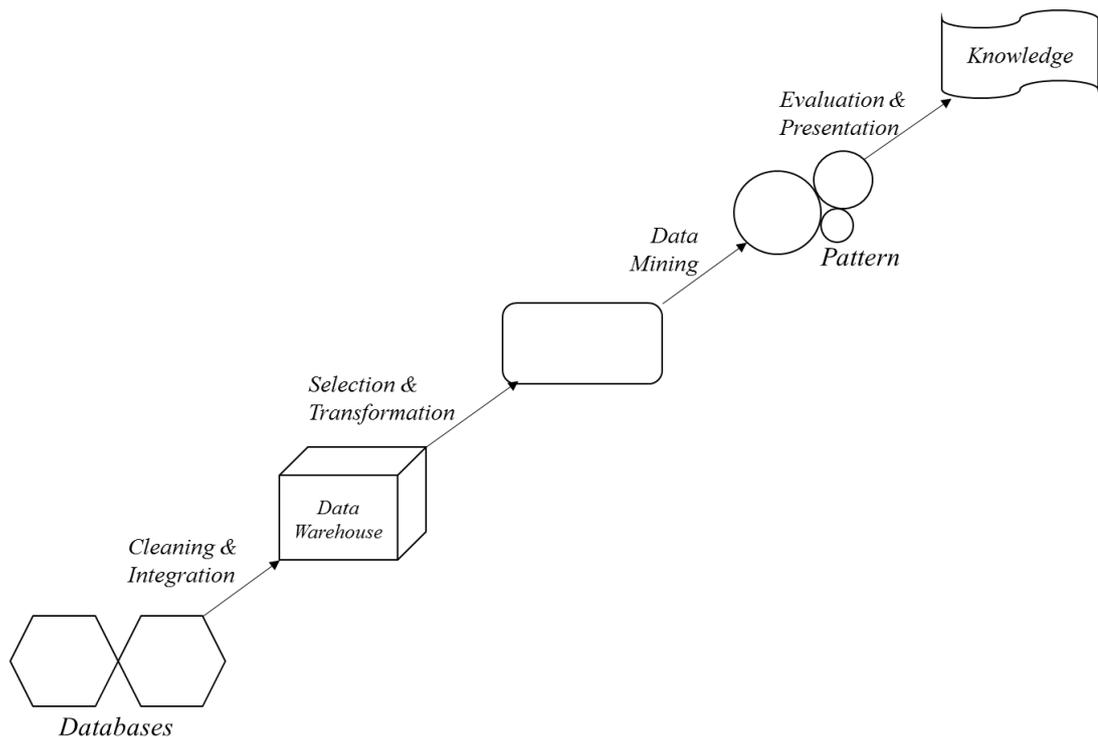
- ***Condition of Economic*** (kondisi ekonomi)

Penilaian kredit hendaknya juga melibatkan penilaian kondisi ekonomi sekarang dan untuk masa yang akan datang sesuai sektor masing-masing. Kondisi perekonomian yang kurang stabil dapat menjadi alasan untuk tidak memberikan kredit.

## 1.2 ***Data Mining***

Terlepas dari namanya yang menunjukkan kecenderungan pengambilan data, secara harfiah *data mining* merupakan proses ekstraksi atau penggalian informasi dari sekelompok data berukuran besar (Han & Kamber, 2006). *Data mining* memiliki sebutan populer lain, yakni: *knowledge mining*, *knowledge extraction*, *data/pattern analysis*, *data archaeology*, dan *data dredging*. Selain istilah tersebut, *data mining* juga biasa dikenal dengan istilah *Knowledge Discovery from Data* (KDD).

Didalam *knowledge discovery from data* (KDD), *data mining* merupakan salah satu tahapan proses ekstraksi informasi. Tahapan proses pada *knowledge discovery from data* dijelaskan pada Gambar 2.1.



Gambar 2.1 Tahapan *Knowledge Discovery from Database* (Han & Kamber, 2006)

Penjelasan tahapan KDD menurut (Han & Kamber, 2006) adalah sebagai berikut :

1. *Data cleaning* merupakan proses pembersihan data dari data yang tidak konsisten
2. *Data integration* penggabungan sumber-sumber data yang berpotensi
3. *Data selection* adalah pengambilan data dari *database* yang memiliki relevansi terhadap analisis yang dilakukan
4. *Data transformation* proses perubahan data ke bentuk yang dibutuhkan untuk melakukan tahapan analisis
5. *Data mining* proses penting yang dibutuhkan untuk mengekstrak informasi dari data
6. *Pattern evaluation* adalah identifikasi pola unik yang merepresentasikan informasi berdasarkan pola-pola yang terjadi
7. *Knowledge presentation* visualisasi serta representasi pola data dan informasi yang telah digali

Melihat kondisi era sekarang yang mengarah pada persaingan global, *data mining* memiliki alasan-alasan penting untuk diterapkan. Berikut ini alasan-alasan penting *data mining* perlu diterapkan menurut (Han & Kamber, 2006):

- Setiap hari, jam, bahkan detik, jutaan hingga milyaran *byte* data mengalir di kehidupan sehari-hari. Aliran data yang sangat cepat berimplikasi pada aliran informasi yang cepat pula. Dengan menerapkan *data mining* maka "knowledge" yang ada pada data dapat dikenali dengan cepat pula.
- Perkembangan teknologi yang pesat menuntut program-program komputer untuk memproses data secara lebih cepat dan lebih akurat bahkan untuk data yang kompleks. Algoritma-algoritma yang ada pada *data mining* dapat memenuhi tuntutan-tuntutan yang ada.

Didalam kehidupan sehari-hari *data mining* dapat diterapkan diberbagai sektor kehidupan. (Gorunescu, 2011) mengatakan bahwa penerapaaan *data mining* dapat ditemukan pada :

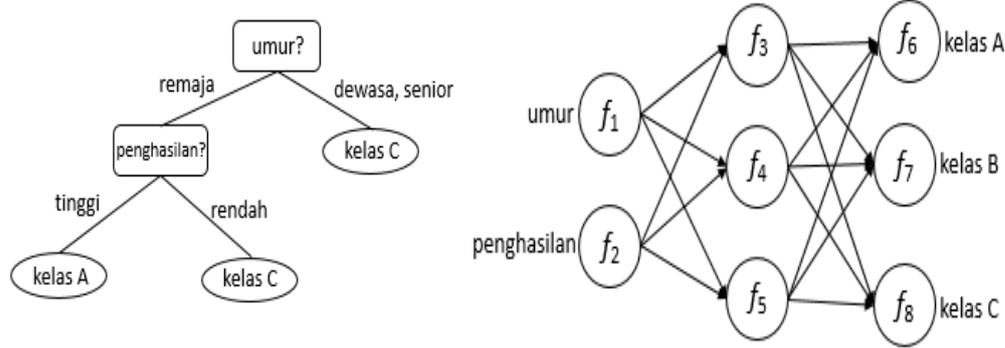
- Ekonomi (bisnis—keuangan) – terdapat banyak data seperti *web-data*, *e-commerce*, *super/hypermarket*, keuangan, dan transaksi perbankan. Aplikasi *data mining* dapat diterapkan untuk :
  - *Churn/attrition analysis*: membangun model untuk memprediksi pelanggan yang akan meninggalkan produk perusahaan dan berpindah ke kompetitor.
  - *Cross-selling/market-basket*: memprediksi produk yang mungkin dibeli secara bersamaan.
  - *Fraud detection*: memprediksi transaksi-transaksi yang tergolong kecurangan.
  - *Customer segmentation*: identifikasi karakteristik umum pelanggan yang membeli produk perusahaan.
  - *Forecasting*: melakukan peralaman berdasarkan data historis.
  - *Risk management*: memprediksi tingkat risiko yang akan dihadapi.
- Kesehatan – terdapat banyak macam dan jenis *database* yang ada dibidang kesehatan yang masih belum sepenuhnya tereksplorasi. Aplikasi *data mining* dapat diterapkan untuk:

- *Medical diagnosis and treatment*: mendiagnosis penyakit dari gejala-gejala yang dialami dan memberikan perawatan pertama
- *Bio-medical and DNA analysis*: prediksi dan analisis dari DNA
- Riset sains – terdapat *database* yang berukuran sangat besar terkumpul selama bertahun-tahun dari berbagai macam bidang ilmu (astronomi, meteorologi, biologi, lingustik, dan lain sebagainya), yang tidak dapat terksplorasi secara menyeluruh dengan metode klasik.

Secara umum metode *data mining* dapat dibagi menjadi dua pendekatan, yakni *supervised learning* dan *unsupervised learning* (Santosa, 2007). Pendekatan pertama, yakni *unsupervised learning*, metode diterapkan tanpa proses latihan (*training*) dan tanpa adanya label. Dalam kasus ini, data dikelompokkan berdasarkan similaritas tertentu. Data dalam satu kelompok memiliki kemiripan yang tinggi dan perbedaan yang signifikan pada kelompok lain. Sebagai contoh, pelanggan suatu produk tertentu dapat dikelompokkan berdasarkan usia, pendidikan, dan pendapatan. Metode yang termasuk dalam pendekatan ini adalah *clustering* dan *Self Organizing Map* (SOM).

Pendekatan kedua, *supervised learning*, metode diterapkan melalui proses pelatihan (*training*) terlebih dahulu. Pendekatan ini mengelompokkan data yang memiliki label tertentu. Pada umumnya data terbagi menjadi dua, yakni data *training* dan data *testing*. Data *training* digunakan untuk mengembangkan model yang akan digunakan untuk prediksi. Data *testing* untuk menguji akurasi dan performansi model prediksi. Metode yang termasuk dalam *supervised learning* adalah *Linier Discriminant Analysis* (LDA), *Logistic Regression*, *Bayes Theorem*, *Decision Tree*, *Artificial Neuron Network* (ANN), dan *Support Vector Machine* (SVM).

umur(X, "remaja") AND penghasilan(X, "tinggi") → kelas(X, "A")  
 umur(X, "remaja") AND penghasilan(X, "rendah") → kelas(X, "B")  
 umur(X, "dewasa") → kelas(X, "C")  
 umur(X, "senior") → kelas(X, "C")



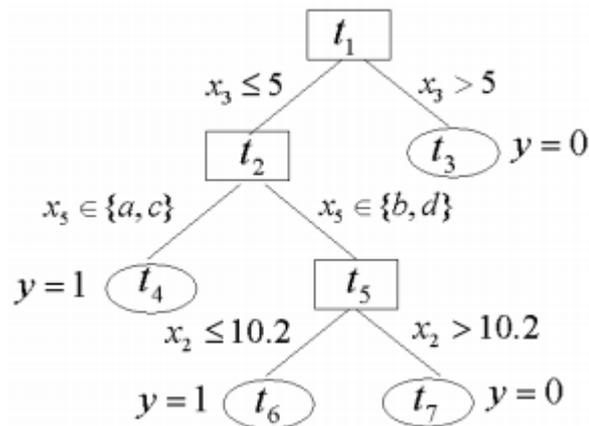
Gambar 2.2 Contoh Model *Supervised Learning* (Han & Kamber, 2006)

Gambar 2.2 diatas merupakan salah satu model *supervised learning* yang terdiri dari: *if-then analysis*, *decision tree*, dan *artificial neuron network*.

### 1.3 Decision Tree

Menurut (Zhang & Hardle, 2008), *Classification and Regression Trees* (CART) merupakan sebuah metode yang digunakan untuk mempelajari hubungan antara *dependent variable* dan sebuah seri *predictor* variabel. CART model juga sering disebut sebagai C&RT dalam beberapa program atau teks statistik. Model CART memilih sebuah kumpulan *predictor* dan interaksinya yang secara optimal memprediksi pengukuran *dependent variable*. Pengembangan model *classification tree* menunjukkan seberapa besar bentuk *classification tree* menunjukkan seberapa besar bentuk *independent* variabel yang secara berbeda memprediksi sebuah *dependent variable*.

Pada Gambar 2.3 ditunjukkan sebuah contoh *classification tree*, dimana *root node*  $t_1$  mencakup semua pengamatan *training* dan *training* data secara rekursif dibagi oleh nilai-nilai variabel-variabel *input*  $x$ 's sampai mencapai *leaf* (terminal) *nodes* ( $t_3$ ,  $t_4$ ,  $t_6$ , dan  $t_7$ ) dimana keputusan klasifikasi untuk  $y$  dibuat untuk semua pengamatan yang termasuk didalamnya. Untuk permasalahan regresi yang mana *dependent* variabel bersifat kontinu, sebuah nilai prediksi untuk *dependent variable* telah ditetapkan untuk semua pengamatan yang terdapat pada setiap *leaf node*.



Gambar 2.3 Contoh *Classification Tree* (Zhang & Hardle, 2008)

Tujuan dari *decision tree* adalah untuk mempartisi data secara sekuensial sehingga dapat memaksimalkan perbedaan pada *dependent variable*. Metode ini juga memiliki kelebihan dibanding teknik regresi dalam kemampuannya untuk mendeteksi *nonlinear relationships*. Kelebihan yang *definite* dari metode *decision tree* dibanding metode lain adalah kemampuannya untuk menjelaskan hasil atau *result* yang didapat.

Didalam menyusun *decision tree*, terdapat dua macam *node*. Yaitu simpul keputusan (*decision node*) dan *leaf node*. *Leaf node* mengindikasikan nilai kelas klasifikasi dari target atribut. Sedangkan *decision node* mengindikasikan dibutuhkan beberapa *test* terhadap nilai atribut tersebut, yang memiliki *outcome* berupa cabang ataupun *sub-tree*.

Kriteria estimasi didalam algoritma *decision tree* adalah pemilihan sebuah atribut untuk diuji pada setiap *decision node*. Tujuan yang ingin dicapai adalah menemukan atribut yang paling berguna dalam mengklasifikasikan data. Pengukuran kuantitatif terhadap ‘ke-bergunaan suatu atribut’ disebut *information gain*. Dimana pengukuran ini, digunakan untuk mengukur seberapa baik sebuah atribut dalam memisahkan data-data *training* sesuai dengan klasifikasinya. Pengukuran ini digunakan untuk memilih dari beberapa kandidat atribut pada setiap langkah dalam membangun *tree*.

Proses pembentukan *decision tree* terdiri dari tiga tahapan, yaitu:

- Pembentukan *Decision Tree*

- Pemilahan (*Classifier*)

Pemilahan dilakukan dengan menggunakan kriteria *goodness-of-split* yang tergantung pada jenis variabel responnya. Metode pemilihan pemilah menggunakan *impurity measure*  $i(t)$ .

$$i(t) = \sum_{i \neq j} p(i|t)p(j|t) \tag{2.01}$$

dengan:

$i(t)$  : *impurity measure* dari simpul  $t$

$p(i|t)$  : peluang kejadian kelas  $i$  pada simpul  $t$

$p(j|t)$  : peluang kejadian kelas  $j$  pada simpul  $t$

*Goodness of Split* merupakan suatu evaluasi pemilahan oleh pemilah  $s$  pada simpul  $t$  yang didefinisikan sebagai penurunan keheterogenan dan didefinisikan sebagai :

$$\emptyset(s, t) = \Delta i(s, t) = i(t) - p_L i(t_L) - p_R i(t_R) \tag{2.02}$$

dengan:

$\emptyset(s, t)$  : nilai *goodness of split* pemilah  $s$  pada simpul  $t$

$p_L i(t_L)$ : peluang kejadian atribut  $L$  pada kelas  $i$  di simpul  $t$

$p_R i(t_R)$ : peluang kejadian atribut  $R$  pada kelas  $i$  di simpul  $t$

- Penentuan Simpul Terminal

Suatu simpul  $t$  akan menjadi simpul terminal atau tidak, akan dipilah kembali bila pada simpul  $t$  tidak terdapat penurunan keheterogenan secara berarti atau adanya batasan minimum  $n$  seperti hanya terdapat satu pengamatan pada tiap simpul anak.

- Penandaan Label Kelas

Penandaan label kelas pada simpul terminal dilakukan berdasarkan aturan jumlah terbanyak. Label kelas simpul terminal  $t$  adalah yang memberi nilai dugaan kesalahan pengklasifikasian simpul  $t$  terbesar. Proses pembentukan *decision tree* berhenti saat terdapat hanya satu pengamatan dalam tiap simpul anak atau adanya batasan minimum  $n$ , semua pengamatan dalam tiap simpul anak identik, dan adanya batasan jumlah level/kedalaman *tree* maksimal.

$$p(j_0|t) = \max_j p(j|t) = \max_j \frac{N_j(t)}{N(t)} \quad (2.03)$$

dengan:

$N_j(t)$  : jumlah pengamatan kelas  $j$  pada simpul  $t$

$N(t)$  : jumlah pengamatan pada simpul  $t$

- Pemangkasan *Decision Tree* (*Prunning*)

Proses ini dilakukan untuk me-simplifikasi bentuk dari *decision tree* didasarkan pada suatu penilaian ukuran sebuah *tree* tanpa mengorbankan ketepatan sehingga didapat ukuran *tree* yang layak.

$$R_\alpha(t) = R(t) + \alpha|T| \quad (2.05)$$

dengan:

$R(t)$  : *resubstitution estimate* (proporsi kesalahan pada sub *tree*)

$\alpha$  : parameter kompleksitas

$|T|$  : ukuran banyaknya simpul terminal pada *tree*  $T$

- Penentuan *Decision Tree* Optimal

Proses ini merupakan suatu kegiatan validasi dan evaluasi mengenai model *decision tree* yang telah dibentuk dengan melakukan metode *cross validation V-fold estimate*.

#### 1.4 Model Evaluasi Akurasi

Model prediksi yang telah dibentuk perlu dilakukan komparasi untuk diuji tingkat akurasi dari tiap model. Sebuah pendekatan pengukuran akurasi yang cukup sederhana dan mudah diaplikasikan adalah matriks konfusius. Didalam matriks konfusius terdapat empat sel yang harus diisi sesuai dengan *output* tiap model. Nilai-nilai ini didapat dari hasil uji model terhadap *testing*. Penjelasan matriks konfusius dapat dilihat pada Tabel 2.1

Tabel 2.1 Matriks Konfusius untuk Klasifikasi Dua Kelas

		Aktual		
		Ya	Tidak	total
Prediksi	Ya	<i>hit</i> (a)	<i>false alarm</i> (b)	prediksi ya
	Tidak	<i>miss</i> (c)	<i>correct negative</i> (d)	prediksi tidak
Total		Aktual ya	Aktual tidak	

(Sumber: Santosa, 2007)

Parameter yang biasanya digunakan untuk pengukuran adalah :

- *Probability of Detection* (POD), mengukur ketepatan prediksi (positif). Nilai POD berkisar dari nol hingga satu. POD bernilai satu bila secara tepat memprediksi kejadian “Ya”.

$$POD = \frac{a}{a+c} \quad (2.05)$$

- *True Negative Rate* (TNR), mengukur ketepatan prediksi (negatif). Nilai TNR berkisar dari nol hingga satu. TNR bernilai satu bila secara tepat memprediksi “Tidak”.

$$TNR = \frac{d}{d+b} \quad (2.06)$$

- *Overall Accuracy* (OA), mengukur ketepatan prediksi secara keseluruhan. Nilai OA bernilai satu apabila secara tepat memprediksi kejadian “Ya” dan “Tidak”.

$$OA = \frac{a+d}{a+b+c+d} \quad (2.07)$$

## 1.5 *Game Theory*

Teori permainan atau yang biasa disebut dengan *game theory* merupakan sebuah metodologi penyelesaian situasi persaingan atau konflik antar pihak dengan pendekatan matematis untuk merumuskan sebuah keputusan secara interaktif (Winston, 2003). Pengambil keputusan dalam *game theory* melibatkan lebih dari satu pengambil keputusan (*decision maker*). Di dalam *game theory*, *decision maker* biasa disebut dengan *player*. Setiap *player* memiliki tujuan masing-masing, dimana implikasi dari setiap keputusan memengaruhi hasil untuk semua *player*. Aktivitas yang saling terkait inilah yang menjadi faktor pembeda *game theory* dengan teori keputusan standar, yang fokus utamanya hanya melibatkan satu pengambil keputusan. Setiap *player* dapat memiliki banyak pilihan strategi yang dapat diterapkan untuk mencapai tujuan yang diinginkan (Maschler, et al., 2013).

Seperti disiplin ilmu lainnya, *game theory* memiliki istilah-istilah tersendiri untuk komponen-komponennya. Beberapa komponen – komponen dari *game theory* menurut (Matsumoto & Szidarovszky, 2016) adalah sebagai berikut:

- *Games*: Situasi interaktif dan strategis dimana terdapat konflik dan kerja sama antar *player*.
- *Player*: Pengambil keputusan didalam *game*. *Player* dapat berupa individu atau kelompok.
- *Strategies*: Keseluruhan kemungkinan keputusan yang dapat diambil oleh *player* dalam *game*.
- *Payoff value*: Hasil yang didapat dari keputusan yang dipilih bersama oleh *player* dalam *game*.

Asumsi dasar didalam *game theory* adalah semua *player* bersifat rasional, dalam arti setiap *player* memaksimalkan usaha mereka untuk mendapatkan hasil yang paling baik. Jumlah *player* dalam *game theory* dibagi menjadi dua jenis yaitu *two person game* dimana *game* diikuti oleh sepasang atau dua orang *player* dan *N-person game* dimana *game* diikuti oleh lebih dari dua *player*.

### 1.5.1 Jenis Games pada Game Theory

*Game theory* dapat dibagi menjadi dua grup utama, yakni *noncooperative games* dan *cooperative games*.

#### 1. *Noncooperative Games*

*Noncooperative Games* merupakan tipe *game* yang tidak terjadi negosiasi ataupun mediasi antar *player* dalam menentukan keputusan dari alternatif strategi yang dimiliki. Tiap *player* memutuskan strategi yang digunakan secara independen satu sama lain.

#### 2. *Cooperative Games*

*Cooperative Games* adalah tipe *game* yang mengakomodasi terjadinya kemungkinan semua *player* akan melakukan koordinasi atau mediasi dalam menentukan strategi yang terbaik untuk semua pihak. Aktivitas kooperasi dapat menyebabkan strategi yang dihasilkan tidak optimal karena terjadi penyesuaian tertentu yang dilakukan kedua pihak.

### 1.5.2 Payoff dalam Game Theory

Terdapat dua jenis tipe *game* dalam *game theory* berdasarkan jumlah pembayaran atau nilai *gamenya*, yaitu:

#### 1. *Zero Sum Games*

*Zero Sum Games* adalah tipe *game* yang menggambarkan jumlah keuntungan yang diterima oleh *Player 1* akan berjumlah sama dengan kerugian yang dirasakan oleh *Player 2* dan sebaliknya. Atau, jika angka keduanya pada matriks *payoff* jika dijumlahkan bernilai 0. Salah satu *game* yang bersifat *zero sum games* adalah *game* kartu poker dimana jumlah uang yang diterima pemenang sama dengan jumlah uang yang dikeluarkan oleh *Player* yang kalah.

#### 2. *Non Zero Sum Games*

*Non Zero Sum Games* adalah tipe *game* yang menggambarkan jumlah keuntungan yang diterima oleh *Player 1* tidak selalu berjumlah sama dengan kerugian yang dirasakan oleh *Player 2* dan sebaliknya. Tipe *game* seperti ini adalah tipe *game* yang sering ditemui di kehidupan sehari-hari karena keputusannya bersifat dinamis dimana bisa saja jika memilih pasangan strategi tertentu keduanya akan menerima keuntungan atau keduanya merasakan kerugian. Biasanya, tipe

game yang digolongkan ke dalam *non zero sum games* merupakan game yang bersifat kompetitif dan tidak memiliki satu strategi optimal atau menggunakan *mixed strategy*. Penulisan nilai *payoff* di dalam matriks *payoff* akan ditulis dengan notasi (a,b) dimana a merupakan keuntungan untuk *Player 1* dan b merupakan keuntungan untuk *Player 2*.

## 2.6 *Inspection Game*

*Inspection Game* merupakan salah satu jenis game pada *game theory* dimana terdapat dua *player* yang saling berhadapan dan saling memengaruhi keputusan yang diambil oleh tiap *player* satu sama lain, dengan kondisi salah satu *player* berperan sebagai *offender* dan yang lain sebagai *enforcer* (Tsebelis, 1989). *Offender* merupakan pihak yang dapat berperan atau berperilaku sesuai dengan peraturan atau melanggar peraturan yang telah ditetapkan *enforcer* dengan tujuan memaksimalkan keuntungan. Tindakan *enforcer* sebagai implikasi perilaku dari *offender* dapat berperan dengan melakukan sanksi atau tidak. *Inspection game* memiliki asumsi dasar yang sama dengan *game theory* yakni kedua *player* bersifat rasional dimana keduanya berusaha untuk memaksimumkan *payoffs*-nya, sehingga masing-masing akan melakukan strategi terbaiknya. Tsebelis, 1989 dalam tulisannya yang berjudul “The Abuse of Probability in Political Analysis: The Robinson Crusoe Fallacy”, berhasil memodelkan *inspection game* antara *offender* dan *enforcer* sekaligus dengan formulasi strategi optimal untuk tiap *player*. Model *inspection game* oleh Tsebelis dapat dilihat pada Tabel 2.2.

Tabel 2. 2 Model *Inspection Game*

		<i>Enforcer</i>	
		<i>Enforce</i>	<i>Not Enforce</i>
<i>Offender</i>	<i>Violate</i>	a1 a2	b1 b2
	<i>Not Violate</i>	c1 c2	d1 d2

(Sumber: Tsebelis, 1989)

a1 : *payoff* untuk *offender* dari skenario *violate-enforce*

b1 : *payoff* untuk *offender* dari skenario *violate-not enforce*

c1 : *payoff* untuk *offender* dari skenario *not violate-enforce*

- d1 : *payoff* untuk *offender* dari skenario *not violate-not enforce*
- a2 : *payoff* untuk *enforcer* dari skenario *violate-enforce*
- b2 : *payoff* untuk *enforcer* dari skenario *violate-not enforce*
- c2 : *payoff* untuk *enforcer* dari skenario *not violate-enforce*
- d2 : *payoff* untuk *enforcer* dari skenario *not violate-not enforce*

Formulasi  $p^*$  dan  $q^*$  yang didapat untuk tiap *player*:

$$p^* = \frac{d_2 - c_2}{a_2 - b_2 - c_2 + d_2} \quad (2.08)$$

$$q^* = \frac{d_1 - b_1}{a_1 - b_1 - c_1 + d_1} \quad (2.09)$$

## 2.7 Dasar Hukum

### 2.7.1 Undang-Undang Republik Indonesia No.10 Tahun 1998

Dalam Undang-Undang ini yang dimaksud dengan:

1. Perbankan adalah segala sesuatu yang menyangkut tentang bank, mencakup kelembagaan, kegiatan usaha, serta cara dan proses dalam melaksanakan kegiatan usahanya;
2. Bank adalah badan usaha yang menghimpun dana dari masyarakat dalam bentuk simpanan dan menyalurkannya kepada masyarakat dalam bentuk kredit dan atau bentuk-bentuk lainnya dalam rangka meningkatkan taraf hidup rakyat banyak;
3. Bank Umum adalah bank yang melaksanakan kegiatan usaha secara konvensional dan atau berdasarkan Prinsip Syariah yang dalam kegiatannya memberikan jasa dalam lalu lintas pembayaran;
4. Bank Perkreditan Rakyat adalah bank yang melaksanakan kegiatan usaha secara konvensional atau berdasarkan Prinsip Syariah yang dalam kegiatannya tidak memberikan jasa dalam lalu lintas pembayaran;
5. Simpanan adalah dana yang dipercayakan oleh masyarakat kepada bank berdasarkan perjanjian penyimpanan dana dalam bentuk giro, deposito,

sertifikat deposito, tabungan dan atau bentuk lainnya yang dipersamakan dengan itu;

6. Giro adalah simpanan yang penarikannya dapat dilakukan setiap saat dengan menggunakan cek, bilyet giro, sarana perintah pembayaran lainnya, atau dengan pemindahbukuan;
7. Deposito adalah simpanan yang penarikannya hanya dapat dilakukan pada waktu tertentu berdasarkan perjanjian Nasabah Penyimpan dengan bank;
8. Sertifikat Deposito adalah simpanan dalam bentuk deposito yang sertifikat bukti penyimpanannya dapat dipindahtangankan;
9. Tabungan adalah simpanan yang penarikannya hanya dapat dilakukan menurut Syarat tertentu yang disepakati, tetapi tidak dapat ditarik dengan cek, bilyet giro, dan atau alat lainnya yang dipersamakan dengan itu;
10. Surat Berharga adalah surat pengakuan utang, wesel, saham, obligasi, sekuritas kredit, atau setiap derivatifnya, atau kepentingan lain, atau suatu kewajiban dari penerbit, dalam bentuk yang lazim diperdagangkan dalam pasar modal dan pasar uang;
11. Kredit adalah penyediaan uang atau tagihan yang dapat dipersamakan dengan itu, berdasarkan persetujuan atau kesepakatan pinjam-meminjam antara bank dengan pihak lain yang mewajibkan pihak peminjam untuk melunasi utangnya setelah jangka waktu tertentu dengan pemberian bunga;
12. Pembiayaan berdasarkan Prinsip Syariah adalah penyediaan uang atau tagihan yang dipersamakan dengan itu berdasarkan persetujuan atau kesepakatan antara bank dengan pihak lain yang mewajibkan pihak yang dibiayai untuk mengembalikan uang atau tagihan tabungan setelah jangka waktu tertentu dengan imbalan atau bagi hasil
13. Prinsip Syariah adalah aturan perjanjian berdasarkan hukum Islam antara bank dan pihak lain untuk penyimpanan dana dan atau pembiayaan kegiatan usaha, atau kegiatan lainnya yang dinyatakan sesuai dengan syariah, antara lain pembiayaan berdasarkan prinsip bagi hasil (mudharabah), pembiayaan berdasarkan prinsip penyertaan modal (musharakah), prinsip jual beli barang dengan memperoleh keuntungan (murabahah), atau pembiayaan barang modal berdasarkan prinsip sewa murni tanpa pilihan (ijarah), atau

- dengan adanya pilihan pemindahan kepemilikan atas barang yang disewa dari pihak bank oleh pihak lain (ijarah wa iqtina);
14. Penitipan adalah penyimpanan harta berdasarkan perjanjian atau kontrak antara Bank Umum dan penitip, dengan ketentuan Bank Umum yang bersangkutan tidak mempunyai hak kepemilikan atas harta tersebut;
  15. Wali Amanat adalah kegiatan usaha yang dapat dilakukan oleh Bank Umum untuk mewakili kepentingan pemegang surat berharga berdasarkan perjanjian antara Bank Umum dengan emiten aural berharga yang bersangkutan;
  16. Nasabah adalah pihak yang menggunakan jasa bank;
  17. Nasabah Penyimpan adalah nasabah yang menempatkan dananya di bank dalam bentuk simpanan berdasarkan perjanjian bank dengan nasabah yang bersangkutan;
  18. Nasabah Debitur adalah nasabah yang memperoleh fasilitas kredit atau pembiayaan berdasarkan Prinsip Syariah atau yang dipersamakan dengan itu berdasarkan perjanjian bank dengan nasabah yang bersangkutan;
  19. Kantor Cabang adalah kantor bank yang secara langsung bertanggung jawab kepada kantor pusat bank yang bersangkutan, dengan alamat tempat usaha yang jelas di mana kantor cabang tersebut. melakukan usahanya;
  20. Bank Indonesia adalah Bank Sentral Republik Indonesia sebagaimana dimaksud dalam Undang-undang yang berlaku;
  21. Pimpinan Bank Indonesia adalah pimpinan sebagaimana dimaksud dalam Undangundang yang berlaku;
  22. Pihak Terafiliasi adalah: a. anggota Dewan Komisaris, pengawas, Direksi atau kuasanya, pejabat, atau karyawan bank; b. anggota pengurus, pengawas, pengelola atau kuasanya, pejabat, atau karyawan bank, khusus bagi bank yang berbentuk hukum koperasi sesuai dengan peraturan perundang-undangan yang berlaku; c. Pihak yang memberikan jasanya kepada bank, antara lain akuntan publik, penilai, konsultan hukum dan konsultan lainnya; d. pihak yang menurut perdamaian Bank Indonesia turut serta mempengaruhi pengelolaan bank, antara lain pemegang saham dan

- keluarganya, keluarga Komisaris, keluarga pengawas, keluarga Direksi.  
keluarga Pengurus;
23. Agunan adalah jaminan tambahan yang diserahkan Nasabah Debitur kepada bank dalam rangka pemberian fasilitas kredit atau pembiayaan berdasarkan Prinsip Syariah;
  24. Lembaga Penjamin Simpanan adalah badan hukum yang menyelenggarakan kegiatan penjaminan atas simpanan Nasabah Penyimpan melalui skim asuransi, dana penyangga, atau skim lainnya;
  25. Merger adalah penggabungan dua bank atau lebih, dengan cara tetap mempertahankan berdirinya salah satu bank dan membubarkan bank-bank lainnya dengan atau tanpa melikuidasi;
  26. Konsolidasi adalah penggabungan dari dua bank atau lebih, dengan cara mendirikan bank baru dan membubarkan bank-bank tersebut. dengan atau tanpa melikuidasi;
  27. Akuisisi adalah pengambilalihan kepemilikan suatu bank;
  28. Rahasia Bank adalah segala sesuatu yang dengan keterangan mengenai nasabah penyimpan dan simpanannya.”

#### 2.7.2 *Peraturan Bank Indonesia Nomor 17/10/PBI/*

## BAB II

### PENGATURAN RASIO LTV ATAU RASIO FTV

#### Bagian Kedua

#### Rasio LTV atau Rasio FTV

#### Pasal 6

Rasio LTV atau Rasio FTV untuk Bank yang memberikan KP dan KP Syariah diatur sebagai berikut:

- a. Rasio LTV atau Rasio FTV untuk KP dan KP Syariah pertama ditetapkan paling tinggi sebesar:
  1. 90% (sembilan puluh persen) untuk KP Rusun dan KP Rusun Syariah dengan luas bangunan 22m<sup>2</sup> (dua puluh dua meter persegi) sampai dengan 70m<sup>2</sup> (tujuh puluh meter persegi);

2. 85% (delapan puluh lima persen) untuk KP Rumah Tapak Syariah dan KP Rusun Syariah berdasarkan akad MMQ atau akad IMBT, dengan luas bangunan di atas 70m<sup>2</sup> (tujuh puluh meter persegi); dan
  3. 80% (delapan puluh persen) untuk KP Rusun, KP Rumah Tapak, KP Rusun Syariah, dan KP Rumah Tapak Syariah berdasarkan akad murabahah atau akad istishna' dengan luas bangunan di atas 70m<sup>2</sup> (tujuh puluh meter persegi).
- b. Rasio LTV atau Rasio FTV untuk KP dan KP Syariah kedua diatur sebagai berikut:
1. Untuk KP kedua ditetapkan paling tinggi sebesar:
    - a) 80% (delapan puluh persen) untuk KP Rumah Tapak dengan luas bangunan 22m<sup>2</sup> (dua puluh dua meter persegi) sampai dengan 70m<sup>2</sup> (tujuh puluh meter persegi);
    - b) 80% (delapan puluh persen) untuk KP Rusun dengan luas bangunan sampai dengan 70m<sup>2</sup> (tujuh puluh meter persegi);
    - c) 80% (delapan puluh persen) untuk KP Ruko atau KP Rukan; dan
    - d) 70% (tujuh puluh persen) untuk KP Rumah Tapak dan KP Rusun dengan luas bangunan di atas 70m<sup>2</sup> (tujuh puluh meter persegi)
  2. Untuk KP Syariah kedua berdasarkan akad murabahah atau akad istishna' ditetapkan paling tinggi sebesar:
    - a) 80% (delapan puluh persen) untuk KP Rumah Tapak Syariah dengan luas bangunan 22m<sup>2</sup> (dua puluh dua meter persegi) sampai dengan 70m<sup>2</sup> (tujuh puluh meter persegi);
    - b) 80% (delapan puluh persen) untuk KP Rusun Syariah dengan luas bangunan sampai dengan 70m<sup>2</sup> (tujuh puluh meter persegi);
    - c) 80% (delapan puluh persen) untuk KP Ruko Syariah atau KP Rukan Syariah; dan
    - d) 70% (tujuh puluh persen) untuk KP Rumah Tapak Syariah dan KP Rusun Syariah dengan luas bangunan di atas 70m<sup>2</sup> (tujuh puluh meter persegi).
  3. Untuk KP Syariah kedua berdasarkan akad MMQ dan IMBT ditetapkan paling tinggi sebesar:

- a) 80% (delapan puluh persen) untuk KP Rumah Tapak Syariah dengan luas bangunan 22m<sup>2</sup> (dua puluh dua meter persegi) sampai dengan 70m<sup>2</sup> (tujuh puluh meter persegi);
  - b) 80% (delapan puluh persen) untuk KP Rusun Syariah dengan luas bangunan sampai dengan 70m<sup>2</sup> (tujuh puluh meter persegi);
  - c) 80% (delapan puluh persen) untuk KP Ruko Syariah atau KP Rukan Syariah; dan
  - d) 75% (tujuh puluh lima persen) untuk KP Rumah Tapak Syariah dan KP Rusun Syariah dengan luas bangunan di atas 70m<sup>2</sup> (tujuh puluh meter persegi).
- c. Rasio LTV atau Rasio FTV untuk KP dan KP Syariah ketiga dan seterusnya diatur sebagai berikut:
1. Untuk KP ketiga dan seterusnya ditetapkan paling tinggi sebesar:
    - a) 70% (tujuh puluh persen) untuk KP Rumah Tapak dengan luas bangunan 22m<sup>2</sup> (dua puluh dua meter persegi) sampai dengan 70m<sup>2</sup> (tujuh puluh meter persegi);
    - b) 70% (tujuh puluh persen) untuk KP Rusun dengan luas bangunan sampai dengan 70m<sup>2</sup> (tujuh puluh meter persegi)
    - c) 70% (tujuh puluh persen) untuk KP Ruko atau KP Rukan; dan
    - d) 60% (enam puluh persen) untuk KP Rumah Tapak dan KP Rusun dengan luas bangunan di atas 70m<sup>2</sup> (tujuh puluh meter persegi).
  2. Untuk KP Syariah ketiga dan seterusnya berdasarkan akad murabahah atau akad istishna' ditetapkan paling tinggi sebesar:
    - a) 70% (tujuh puluh persen) untuk KP Rumah Tapak Syariah dengan luas bangunan 22m<sup>2</sup> (dua puluh dua meter persegi) sampai dengan 70m<sup>2</sup> (tujuh puluh meter persegi);
    - b) 70% (tujuh puluh persen) untuk KP Rusun Syariah dengan luas bangunan sampai dengan 70m<sup>2</sup> (tujuh puluh meter persegi);
    - c) 70% (tujuh puluh persen) untuk KP Ruko Syariah atau KP Rukan Syariah; dan

- d) 60% (enam puluh persen) untuk KP Rumah Tapak Syariah dan KP Rusun Syariah dengan luas bangunan di atas 70m<sup>2</sup> (tujuh puluh meter persegi).
3. Untuk KP Syariah ketiga dan seterusnya berdasarkan akad MMQ dan IMBT ditetapkan paling tinggi sebesar:
- a) 70% (tujuh puluh persen) untuk KP Rumah Tapak Syariah dengan luas bangunan 22m<sup>2</sup> (dua puluh dua meter persegi) sampai dengan 70m<sup>2</sup> (tujuh puluh meter persegi);
  - b) 70% (tujuh puluh persen) untuk KP Rusun Syariah dengan luas bangunan sampai dengan 70m<sup>2</sup> (tujuh puluh meter persegi);
  - c) 70% (tujuh puluh persen) untuk KP Ruko Syariah atau KP Rukan Syariah; dan
  - d) 65% (enam puluh lima persen) untuk KP Rumah Tapak Syariah dan KP Rusun Syariah dengan luas bangunan di atas 70m<sup>2</sup> (tujuh puluh meter persegi).

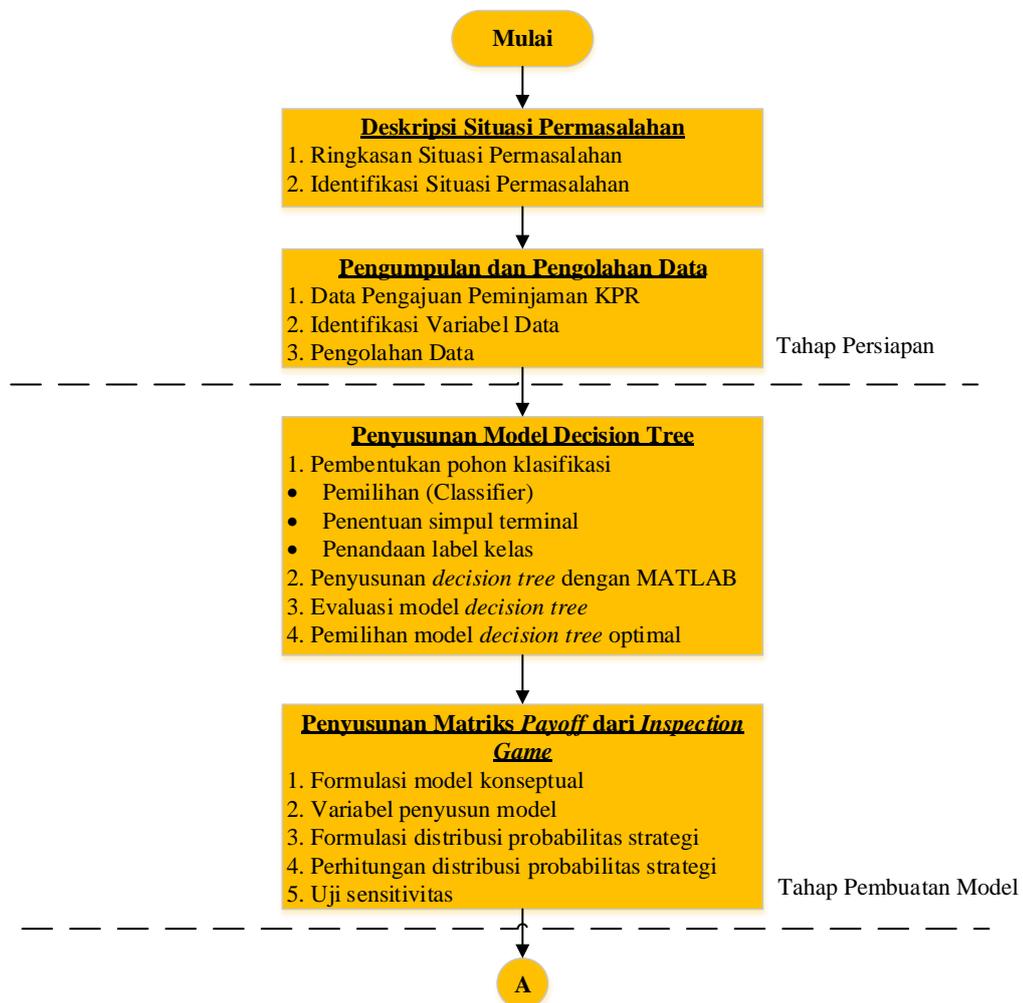
# BAB 3

## METODOLOGI PENYELESAIAN MASALAH

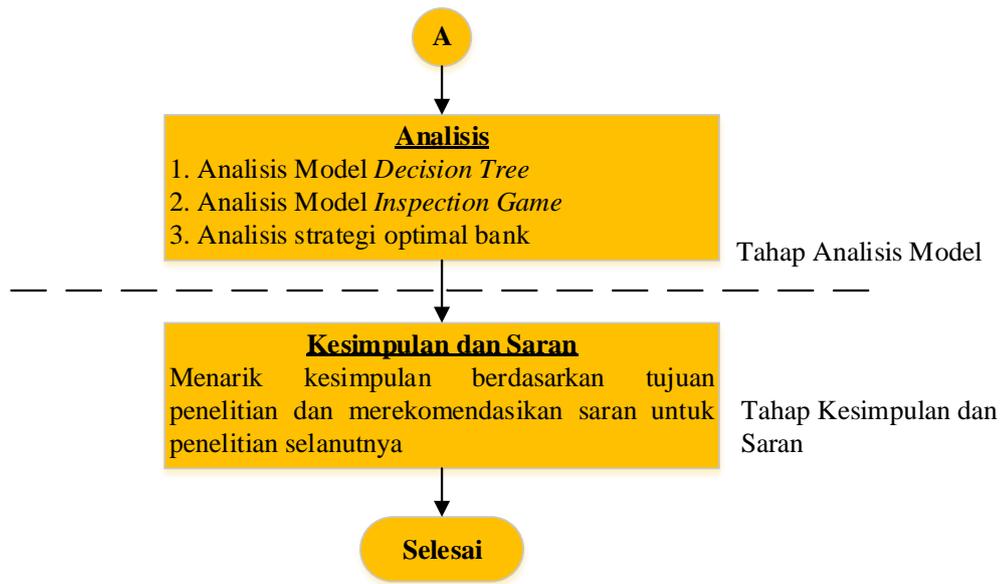
Bab ini akan menjelaskan mengenai metodologi penyelesaian masalah berupa alur pelaksanaan penelitian dan penjelasan dari alur pelaksanaan penelitian.

### 3.1 Alur Penyelesaian Masalah

Berikut merupakan alur pelaksanaan penelitian tugas akhir yang menjadi dasar dalam pelaksanaan penelitian.



Gambar 3.1 *Flowchart* Penyelesaian Masalah



Gambar 3.2 *Flowchart* Penyelesaian Masalah (lanjutan)

## 3.2 Tahap Persiapan

### 3.2.1 Deskripsi Situasi Permasalahan

Tahap persiapan diawali dengan deskripsi situasi permasalahan. Langkah ini bertujuan untuk mengetahui elemen-elemen permasalahan yang terdapat pada permasalahan kredit macet yang dihadapi oleh Bank X. Setelah mengetahui elemen-elemen permasalahan, diharapkan dapat mengambil suatu solusi yang dapat menjadi jalan keluar dari permasalahan kredit macet. Permasalahan yang dihadapi oleh Bank X mengenai pengajuan kredit terjadi pada jenis Kredit Pemilikan Rumah (KPR). Data bulan Juli hingga Desember 2016 menunjukkan jumlah nasabah yang mengajukan KPR menunjukkan kecenderungan meningkat. Permintaan peningkatan mengalami kenaikan dengan rata-rata sebesar 9,36%. Permohonan paling sedikit terjadi pada bulan Juli yakni 123 debitur dan paling banyak terjadi pada bulan November yakni 195 debitur. Menurut informasi yang didapat, hal ini tidak sebanding dengan jumlah analis kredit yang ada di Bank X. Analis kredit yang hanya berjumlah lima orang hanya mampu mengevaluasi 15-20 permohonan kredit tiap minggunya. Metode *credit scoring* yang digunakan memang membutuhkan waktu (*time consuming*). Sehingga tak jarang debitur memberi umpan balik berupa kekecewaan mengenai lamanya kepastian persetujuan proposal pengajuannya. Permasalahan lain yang terjadi di Bank X adalah mengenai tingkat kolektabilitas

kredit yang diberikan. Data bulan Juli-Desember 2016, sebanyak 912 debitur KPR telah didapatkan. Dari jumlah tersebut, hanya 90% menunjukkan kolektabilitas yang baik. Kondisi kolektabilitas kredit yang tidak maksimal menyebabkan Bank X harus mengeluarkan biaya lebih untuk mengumpulkan angsuran yang harus dibayarkan oleh debitur secara langsung. Dampak lain yang disebabkan oleh macetnya kredit yang diberikan adalah *time value* dari suku bunga yang harusnya didapatkan oleh pihak bank apabila debitur membayar tepat waktu. Menanggapi hal tersebut, Bank X menetapkan target kolektabilitas kredit sebesar 95%.

Untuk memudahkan proses identifikasi elemen permasalahan kredit macet, digunakan pendekatan identifikasi enam elemen permasalahan (Daellenbach & McNickle, 2005). Berikut ini merupakan enam elemen permasalahan kredit macet:

- Pengambil Keputusan  
Pengambil keputusan pada permasalahan kredit macet yang merupakan kejadian sebab akibat yang saling memengaruhi adalah analisis kredit Bank X.
- Objektif Keputusan  
Objektif atau tujuan dari permasalahan ini adalah bagaimana bank dapat mengambil suatu kebijakan yang dapat meminimasi kesalahan prediksi nasabah dalam melakukan pembayaran dan meminimasi tendensi nasabah untuk melakukan kredit macet.
- Kriteria Pemilihan  
Kriteria pemilihan keputusan pada permasalahan kredit macet adalah meminimumkan kesalahan prediksi, meminimumkan jumlah nasabah yang akan melakukan kredit macet dan memaksimalkan keuntungan dari pemberian kredit.
- Ukuran Performansi  
Ukuran performansi yang digunakan pada permasalahan ini adalah, tingkat kesalahan prediksi, jumlah nasabah yang melakukan kredit macet, keuntungan yang diperoleh nasabah, dan keuntungan yang diperoleh bank.

- Kontrol Masukan atau Alternatif Tindakan

Kontrol masukan dalam permasalahan ini adalah kebijakan sanksi dan kebijakan penghargaan yang dapat dilakukan oleh bank. Alternatif tindakan yang dapat dilakukan adalah penambahan atau pengurangan nilai sanksi dan penghargaan yang diberikan.

### 3.2.2 Pengumpulan dan Pengolahan Data

Data yang digunakan untuk tugas akhir ini merupakan data proposal pengajuan KPR di Bank X yang mengandung atribut-atribut yang berguna untuk proses analisis. Data yang digunakan berjumlah 912 data dari bulan Juli hingga Desember 2016. Data yang didapat selanjutnya diidentifikasi mengenai jenis variabel dan rentang nilainya untuk memudahkan proses selanjutnya.

Tabel 3.1 Variabel Penelitian

No	Atribut	Variabel	Tipe	Keterangan
1	Status	(Y)	Kategorikal	1. Lancar
				2. Macet
2	Besaran Pinjaman	(X <sub>1</sub> )	Numerik	min : Rp. 53.500.000
				max: Rp. 3.000.000.000
3	Tenor	(X <sub>2</sub> )	Numerik	min : 36 bulan
				max: 300 bulan
4	Nilai Agunan	(X <sub>3</sub> )	Numerik	min : Rp. 105.060.000
				max: Rp. 3.600.000.000
5	Pendapatan	(X <sub>4</sub> )	Numerik	min : Rp. 1.853.333
				max: Rp. 171.888.888
6	Proporsi Pembiayaan	(X <sub>5</sub> )	Numerik	min : 0,10
				max: 0,96
7	Jenis Pekerjaan	(X <sub>6</sub> )	Kategorikal	1. Industri
				2. Jasa
				3. Pendidikan
				4. Properti
				5. Perdagangan
				6. Perbankan
				7. Transportasi
				8. Wirausaha
				9. Pegawai Negeri
				10. lain-lain

Tabel 3.1 menjelaskan mengenai atribut-atribut yang digunakan, tipe dari tiap-tiap atribut, serta beberapa informasi mengenai atribut yang ada. Setelah didapatkan variabel-variabel yang akan digunakan untuk penyusunan model, maka selanjutnya adalah dilakukan definisi operasional dari setiap variabel. Berikut ini merupakan definisi operasional untuk tiap variabel:

1. Status

Status merupakan kondisi pembayaran angsuran nasabah kepada Bank tiap bulannya. Status nasabah dikategorikan lancar apabila pembayaran angsuran pokok dan/atau bunga tepat waktu, memiliki mutasi rekening yang aktif, atau bagian dari kredit yang dijamin dengan agunan tunai. Status nasabah dikategorikan macet apabila terdapat tunggakan pembayaran angsuran pokok dan/atau bunga yang melampaui 270 hari. Variabel status pada penyusunan model *decision tree* nantinya akan menjadi variabel respon.

2. Besar Pinjaman

Besar pinjaman merupakan besarnya hutang yang dipinjam oleh nasabah, yang nilainya bergantung pada nilai agunan dan kapabilitas nasabah untuk melunasinya.

3. Tenor

Tenor merupakan jangka waktu yang diberikan bank pada nasabah untuk melunasi hutang dengan membayar angsuran pokok dan bunga tiap bulannya.

4. Nilai Agunan

Nilai agunan ialah besarnya nilai apresiasi rumah yang menjadi objek pembiayaan sekagilus menjadi jaminan selama hutang nasabah belum terlunasi. Nilai Agunan menjadi representasi *collateral* pada *5C principle*.

5. Pendapatan

Pendapatan adalah besar pemasukkan yang diperoleh nasabah tiap bulannya yang sebagian besarnya menjadi kewajiban untuk melunasi hutang dengan membayarkan angsuran tiap bulannya. Variabel pendapatan menjadi representasi *capacity* dan *capital* pada *5C principle*.

## 6. Proporsi Pembiayaan

Proporsi Pembiayaan merupakan *financial to value* (FTV) yang dapat diberikan bank kepada nasabah. FTV merupakan nilai maksimal yang dapat bank keluarkan untuk membantu pembiayaan nasabah dalam kepemilikan rumah.

## 7. Jenis Pekerjaan

Jenis pekerjaan adalah sektor pekerjaan dimana nasabah bekerja. Jenis pekerjaan dikelompokkan menjadi sepuluh, yakni sektor industri, jasa, pendidikan, properti, perdagangan, perbankan, transportasi, wirausaha, pegawai negeri, dan sektor lainnya. Jenis pekerjaan menjadi representasi *character*, *capacity*, dan *capital*.

### 3.3 Tahap Pembuatan Model

Tahap pembuatan model terdiri dari dua proses penyusunan model, yakni penyusunan model *decision tree* dan penyusunan matriks *payoff* dari *inspection game*.

#### 3.3.1 Penyusunan Model *Decision Tree*

Data pemohon kredit yang telah diolah dan dinormalisasi, maka didapatkan enam variabel *predictor* dan satu variabel respon. Variabel-variabel tersebut digunakan untuk menyusun model *decision tree*. Langkah-langkah yang ditempuh untuk menyusun model tersebut adalah:

- Pembentukan *Decision Tree*

Langkah pembentukan *decision tree* dilakukan dengan tiga tahapan, yaitu:

- Pemilahan (*Classifier*)

Pemilahan dilakukan tergantung pada jenis variabel respon, untuk tugas akhir ini, terdapat satu jenis variabel respon berjumlah 912 data. Metode pemilihan pemilah menggunakan *impurity measure*  $i(t)$ . Kejadian “lancar” pada variabel respon terjadi sebanyak 766, sedang untuk kejadian “macet” pada variabel respon terjadi sebanyak 146.

$$i(t) = \sum_{i \neq j} p(i|t)p(j|t) \quad (3.01)$$

Peluang kejadian “lancar” pada variabel respon  $y$  mengikuti persamaan (3.01), dengan perhitungan sebagai berikut:

$$p(i|y) = \frac{i}{y}$$

$$p(i|y) = \frac{665}{800}$$

$$p(i|y) = 0,83125$$

Peluang kejadian “macet” pada variabel respon  $y$  mengikuti persamaan (3.01), dengan perhitungan sebagai berikut:

$$p(j|y) = \frac{j}{y}$$

$$p(j|y) = \frac{135}{800}$$

$$p(j|y) = 0,16875$$

Setelah mendapat peluang tiap kejadian pada variabel respon  $y$ , maka dihitung *impurity measure*  $i(y)$  menggunakan persamaan (3.01), dengan perhitungan sebagai berikut:

$$i(y) = \sum_{i \neq j} p(i|y)p(j|y)$$

$$i(y) = \sum_{i \neq j} 0,83125 \times 0,16875$$

$$i(y) = 0.140273$$

Langkah selanjutnya adalah menentukan pemilah dengan menggunakan kriteria *goodness of split*, akan tetapi sebelum menghitung *goodness of split* harus dilakukan diskritisasi untuk variabel yang beratribut numerik seperti nominal pinjaman ( $x_1$ ), tenor ( $x_2$ ), nilai agunan ( $x_3$ ), pendapatan ( $x_4$ ), dan proporsi pembayaran ( $x_5$ ). Hal ini bertujuan untuk

mendapatkan pemilah yang dapat memberikan penurunan heterogenitas yang signifikan. Contoh diskritisasi untuk variabel nominal pinjaman ( $x_1$ ):

Perhitungan persebaran data pada variabel  $x_1$

$$d = |b - a|$$

$$d = |2880 - 53,5|$$

$$d = 2826.5$$

$$L = \frac{d}{4}$$

$$L = \frac{2826.5}{4}$$

$$L = 706.625$$

Penentuan posisi pemilah pada variabel  $x_1$

$$t_1 = a + L$$

$$t_1 = 53,5 + 706.625$$

$$t_1 = 760.125$$

$$t_2 = a + 2L$$

$$t_2 = 53,5 + 1413.25$$

$$t_2 = 1466.75$$

$$t_3 = b - L$$

$$t_3 = 2880 - 706.625$$

$$t_3 = 2173.375$$

Setelah mendapatkan posisi pemilah pada variabel  $x_1$ , maka dapat dilakukan perhitungan *goodness of split* pada tiap posisi pemilah. Proporsi kejadian pada variabel respon  $y$  untuk tiap posisi pemilah  $t$  disajikan pada Tabel 3.2.

Tabel 3.2 Proporsi Kejadian Lancar-Macet

x1	760,125		1466,75		2173,375	
	<=	>	<=	>	<=	>
Lancar	656	9	664	1	664	1
Macet	135	0	135	0	135	0

Perhitungan *goodness of split* mengikuti persamaan (3.02). Berikut merupakan perhitungan *goodness of split* pada pemilah t1 variabel x1:

$$\emptyset(s, t) = \Delta i(s, t) = i(y) - p_L i(t_L) - p_R i(t_R) \quad (3.02)$$

Perhitungan proporsi seluruh kejadian pada kelompok kiri pemilah terhadap seluruh kejadian:

$$p_L = \frac{(656 + 135)}{800}$$

$$p_L = \frac{791}{800}$$

$$p_L = 0,98875$$

Perhitungan proporsi seluruh kejadian pada kelompok kanan pemilah terhadap seluruh kejadian:

$$p_R = \frac{(9 + 0)}{800}$$

$$p_R = \frac{9}{800}$$

$$p_R = 0,01125$$

Perhitungan *impurity measure* pada kelompok kiri pemilah:

$$i(t_L) = \sum_{i \neq j} p(i|t_L)p(j|t_L)$$

$$i(t_L) = \sum_{i \neq j} 0,82933 \times 0,17067$$

$$i(t_L) = 0,14154$$

Perhitungan *impurity measure* pada kelompok kanan pemilah:

$$i(t_R) = \sum_{i \neq j} p(i|t_R)p(j|t_R)$$

$$i(t_R) = \sum_{i \neq j} 1 \times 0$$

$$i(t_R) = 0$$

Perhitungan *goodness of split* untuk pemilah t1:

$$\emptyset(s, t) = \Delta i(s, t) = i(y) - p_L i(t_L) - p_R i(t_R)$$

$$\emptyset(s, t) = \Delta i(s, t) = 0,140273 - (0,98875 \times 0,14154) - (0,01125 \times 0)$$

$$\emptyset(s, t) = \Delta i(s, t) = 0,000324$$

Perhitungan yang sama dilakukan untuk mendapatkan *goodness of split* pada pemilah yang lain. Hasil perhitungan *goodness of split* untuk pemilah pada variabel x1 ditampilkan pada Tabel 3.3

Tabel 3.3 *Goodness of Split* Pemilah x1

x1	760,125		1466,75		2173,375	
	<=	>	<=	>	<=	>
Lancar	656	9	664	1	664	1
Macet	135	0	135	0	135	0
Gini	0,000324006		3,56403E-05		3,56403E-05	

Hasil perhitungan *goodness of split* untuk pemilah pada variabel x2 ditampilkan pada Tabel 3.4

Tabel 3.4 *Goodness of Split* Pemilah x2

x2	102		168		282	
	<=	>	<=	>	<=	>
Lancar	14	651	139	526	663	2
Macet	10	125	26	109	58	77
Gini	0,001900907		3,24449E-05		0,071168906	

Hasil perhitungan *goodness of split* untuk pemilah pada variabel x3 ditampilkan pada Tabel 3.5

Tabel 3.5 *Goodness of Split* Pemilah x3

x3	978,795		1852,53		2726,265	
	<=	>	<=	>	<=	>
Lancar	650	15	664	1	664	1
Macet	130	5	135	0	135	0
Gini	0,000169271		3,56403E-05		3,56403E-05	

Hasil perhitungan *goodness of split* untuk pemilah pada variabel x4 ditampilkan pada Tabel 3.6

Tabel 3.6 *Goodness of Split* Pemilah x4

x4	25,18		48,79		72,39	
	<=	>	<=	>	<=	>
Lancar	658	7	663	2	663	2
Macet	135	0	135	0	135	0
Gini	0,000251369		7,13698E-05		7,13698E-05	

Hasil perhitungan *goodness of split* untuk pemilah pada variabel x5 ditampilkan pada Tabel 3.7

Tabel 3.7 *Goodness of Split* Pemilah x5

x5	0,319		0,5345		0,749	
	<=	>	<=	>	<=	>
Lancar	2	661	17	646	199	464
Macet	7	50	38	19	54	3
Gini	0,006177943		0,030951254		0,009767311	

Hasil perhitungan *goodness of split* untuk pemilah pada variabel x6 ditampilkan pada Tabel 3.8 dan Tabel 3.9

Tabel 3.8 *Goodness of Split* Pemilah x6

x6	1		2		3		4		5	
	<=	>	<=	>	<=	>	<=	>	<=	>
Lancar	33	632	109	556	97	568	94	571	135	530
Macet	4	131	19	116	34	101	34	101	14	121
Gini	0,000178329		7,859E-05		0,001614136		0,001787574		0,001280252	

Tabel 3.9 *Goodness of Split* Pemilah x6 (lanjutan)

x6	6		7		8		9		10	
	<=	>	<=	>	<=	>	<=	>	<=	>
Lancar	57	608	45	620	27	638	37	628	31	634
Macet	8	127	11	124	5	130	4	131	2	133
Gini	0,000184479		5,76637E-05		6,51042E-06		0,000273759		0,00050318	

Setelah mendapatkan seluruh nilai *goodness of split* dari setiap pemilah t pada variabel x, dipilih pemilah terbaik dengan meninjau nilai *goodness of split* yang terbesar yang dijadikan pemilah. Tabel 3.10 menampilkan pemilah t terbaik pada tiap variabel x.

Tabel 3.10 Nilai *Goodness of Split*

var(t)	<i>goodness of split</i>
x1(760,125)	0,000324006
x2(282)	0,071168906
x3(978,795)	0,000169271
x4(25,18)	0,000251369
x5(0,5345)	0,028703579
x6(4)	0,001787574

Pemilah yang akan dijadikan simpul akar adalah pemilah var(t) yang memiliki nilai *goodness of split* yang paling tinggi dibanding pemilah lainnya. Pada tabel 3.8 pemilah var(t) yang memiliki nilai *goodness of split* paling tinggi adalah x2(282) dengan 0,071168906

- Penentuan Simpul Terminal

Pemilahan yang dilakukan oleh pemilah x2(282) belum memberikan penurunan heterogenitas yang signifikan, sehingga perlu dilakukan perhitungan *goodness of split* kembali untuk menentukan simpul terminal. Penurunan heterogenitas yang belum signifikan terjadi pada kelompok kiri pemilah, yakni jumlah kejadian pada kelompok kiri pemilah berjumlah 720 pengamatan, dengan banyak kejadian “lancar” sejumlah 663 pengamatan dan kejadian “macet” sejumlah 57 pengamatan, sehingga perlu dilakukan perhitungan *goodness of split* kembali untuk memilih variabel selanjutnya sebagai simpul terminal. Metode perhitungan yang sama dengan pemilihan pemilah dilakukan, berikut tahapan perhitungan *goodness of split* untuk memilih simpul terminal:

Peluang kejadian “lancar” pada variabel respon y mengikuti persamaan (3.01), dengan perhitungan sebagai berikut:

$$p(i|y_t) = \frac{i}{y_t}$$

$$p(i|y_t) = \frac{663}{720}$$

$$p(i|y_t) = 0,92083$$

Peluang kejadian “macet” pada variabel respon y mengikuti persamaan (3.01), dengan perhitungan sebagai berikut:

$$p(j|y_t) = \frac{j}{y_t}$$

$$p(j|y_t) = \frac{57}{720}$$

$$p(j|y_t) = 0,07917$$

Setelah mendapat peluang tiap kejadian pada variabel respon  $y$ , maka dihitung *impurity measure*  $i(y)$  menggunakan persamaan (3.01), dengan perhitungan sebagai berikut:

$$i(y_t) = \sum_{i \neq j} p(i|y_t)p(j|y_t)$$

$$i(y_t) = \sum_{i \neq j} 0,92083 \times 0,07917$$

$$i(y_t) = 0.0729021$$

Langkah selanjutnya adalah perhitungan *goodness of split* untuk tiap pemilah pada kelompok kiri pemilah, hasil perhitungan *goodness of split* untuk pemilah pada variabel  $x_1$  ditampilkan pada Tabel 3.11

Tabel 3.11 *Goodness of Split* Kelompok Kiri Pemilah  $x_1$

x1	760,125		1466,75		2173,375	
	<=	>	<=	>	<=	>
Lancar	654	9	662	1	662	1
Macet	57	0	57	0	57	0
Gini	7,93337E-05		8,71677E-06		8,71677E-06	

Hasil perhitungan *goodness of split* untuk pemilah pada variabel  $x_3$  ditampilkan pada Tabel 3.12

Tabel 3.12 *Goodness of Split* Kelompok Kiri Pemilah  $x_3$

x3	978,795		1852,53		2726,265	
	<=	>	<=	>	<=	>
Lancar	648	15	662	1	662	1
Macet	54	3	57	0	57	0
Gini	0,000543536		8,71677E-06		8,71677E-06	

Hasil perhitungan *goodness of split* untuk pemilah pada variabel  $x_4$  ditampilkan pada Tabel 3.13

Tabel 3.13 *Goodness of Split* Kelompok Kiri Pemilah x4

x4	25,18		48,79		72,39	
	<=	>	<=	>	<=	>
Lancar	656	7	661	2	662	1
Macet	57	0	57	0	57	0
Gini	6,15309E-05		1,74578E-05		8,71677E-06	

Hasil perhitungan *goodness of split* untuk pemilah pada variabel x5 ditampilkan pada Tabel 3.14.

Tabel 3.14 *Goodness of Split* Kelompok Kiri Pemilah x5

x5	0,319		0,5345		0,749	
	<=	>	<=	>	<=	>
Lancar	2	661	17	646	199	464
Macet	7	50	38	19	54	3
Gini	0,006177943		0,030951254		0,009767311	

Hasil perhitungan *goodness of split* untuk pemilah pada variabel x6 ditampilkan pada Tabel 3.15 dan Tabel 3.16.

Tabel 3.15 *Goodness of Split* Kelompok Kiri Pemilah x6

x6	1		2		3		4		5	
	<=	>	<=	>	<=	>	<=	>	<=	>
Lancar	33	630	109	554	95	568	94	569	135	528
Macet	2	55	14	43	17	40	9	48	2	55
Gini	2,47835E-05		0,000247428		0,000971439		1,12576E-05		0,000979689	

Tabel 3.16 *Goodness of Split* Kelompok Kiri Pemilah x6 (lanjutan)

x6	6		7		8		9		10	
	<=	>	<=	>	<=	>	<=	>	<=	>
Lancar	57	606	45	618	27	636	37	626	31	632
Macet	3	54	4	53	2	55	2	55	2	55
Gini	7,73359E-05		4,44074E-07		4,36735E-06		4,45294E-05		1,65478E-05	

Penentuan variabel sebagai simpul terminal mengikuti aturan yang sama dengan penentuan pemilah. Pemilah terbaik  $t_2$  sebagai calon simpul terminal, dapat dilihat pada Tabel 3.17

Tabel 3.17 Nilai *Goodness of Split*

var(t)	<i>goodness of split</i>
x1(760,125)	7,93337E-05
x3(978,795)	0,000543536
x4(25,18)	6,15309E-05
x5(0,5345)	0,030951254
x6(4)	0,000979689

Pemilah yang akan dijadikan simpul terminal adalah pemilah var(t) yang memiliki nilai *goodness of split* yang paling tinggi dibanding pemilah lainnya. Pada Tabel 3.15 pemilah var(t) yang memiliki nilai *goodness of split* paling tinggi adalah x5(0.5345) dengan 0,030951254.

- o Penandaan Label Kelas

Penandaan label kelas pada simpul terminal dilakukan berdasarkan aturan jumlah terbanyak. Label kelas simpul terminal  $t$  adalah yang memberi nilai dugaan kesalahan pengklasifikasian simpul  $t$  terbesar. Proses pembentukan *decision tree* berhenti saat terdapat hanya satu pengamatan dalam tiap tiap simpul anak atau adanya batasan minimum  $n$ , semua pengamatan dalam tiap simpul anak identik, dan adanya batasan jumlah level/kedalaman *tree* maksimal.

$$p(j_0|t) = \max_j p(j|t) = \max_j \frac{N_j(t)}{N(t)} \quad (3.03)$$

Penentuan label kelas mengikuti persamaan (3.03), dengan contoh perhitungan sebagai berikut:

Jumlah kejadian pada kelompok kiri pemilah  $x_5(0,5435)$  terdapat 40 kejadian, dengan jumlah kejadian “lancar” sebanyak tiga dan kejadian “macet” sebanyak 37.

$$p(i|t) = \frac{i}{t}$$

$$p(i|t) = \frac{3}{40}$$

$$p(i|t) = 0,075$$

$$p(j|t) = \frac{j}{t}$$

$$p(j|t) = \frac{37}{40}$$

$$p(j|t) = 0,925$$

$$K = \max(p(i|t), p(j|t))$$

$$K = \max(0,075, 0,925)$$

$$K = 0,925$$

*Kelas = "Macet"*

- Pembentukan *Decision Tree* Menggunakan *MATLAB*

Skenario penyusunan *decision tree* menggunakan *software MATLAB R2010a*, pertama-tama dilakukan pemuatan data dari variabel-variabel *predictor* dan variabel respon dari data pemohon KPR.

Langkah selanjutnya adalah membagi data menjadi dua kelompok, yakni data *training* dan data *testing*. Proporsi pembagian kelompok mengikuti aturan pembagian 75%-25%, 80%-20%, 85%-15%, 90%-10%, dan 95%-15%. Hal ini bertujuan untuk proses validasi model *decision tree* untuk mengetahui tingkat keakuratan dari model.

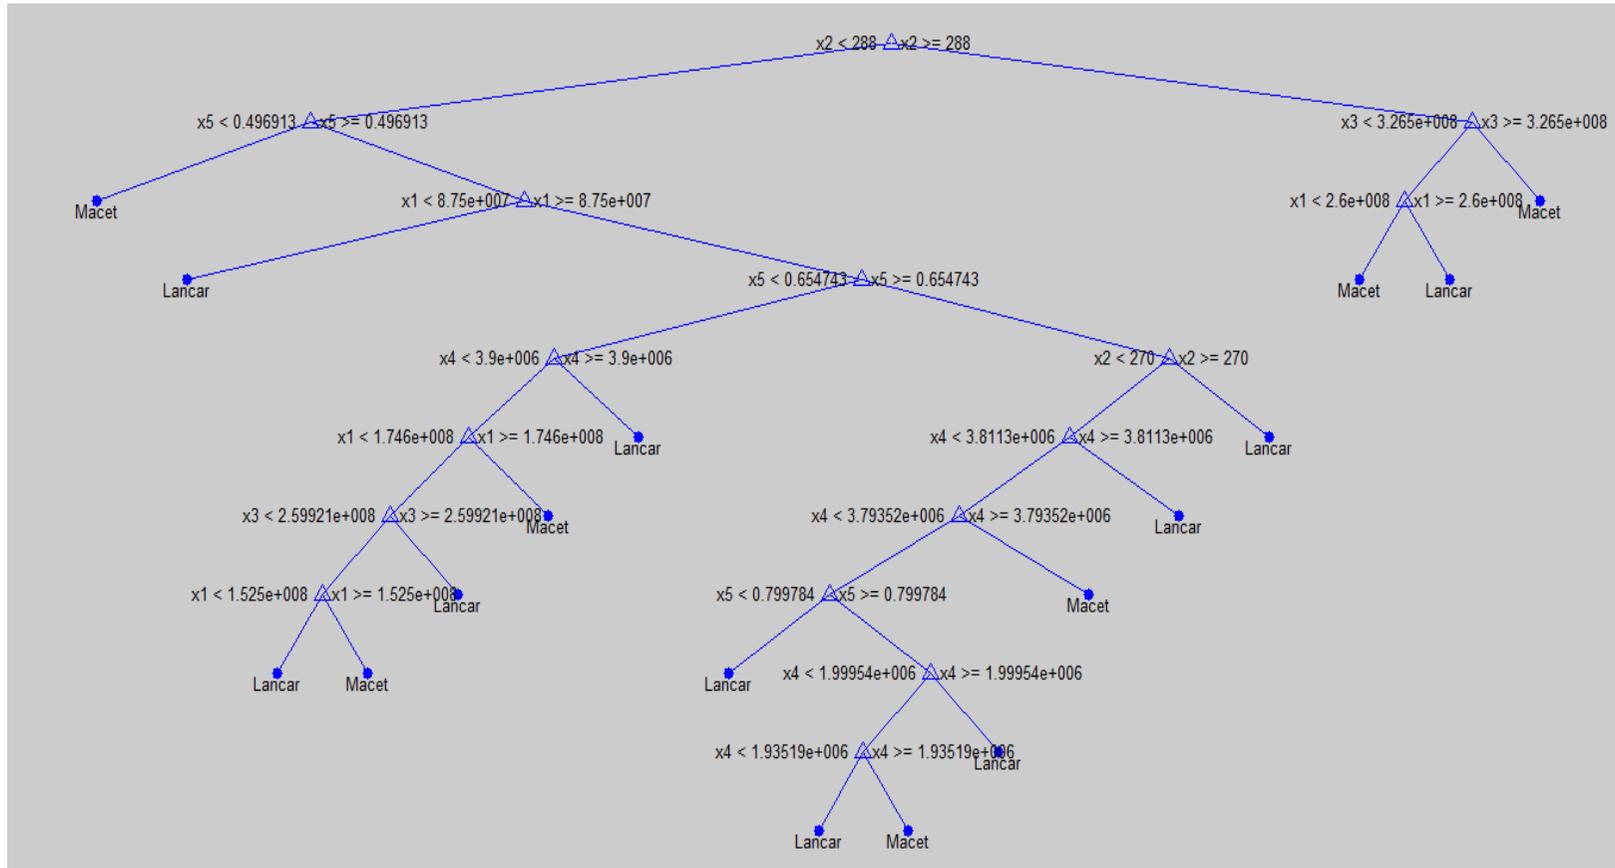
Model *decision tree* pertama yang dibuat adalah *decision tree* dengan komposisi 75% data *training* dan 25% data *testing*. Model *decision tree* yang didapat untuk komposisi ini terdiri dari lima variabel *predictor* yang digunakan, 16 simpul terminal, dan 17 simpul daun. Bentuk dari *decision tree* 75%-25% ditampilkan pada Gambar 3.3. Selain bentuk dari *decision*

*tree* itu sendiri keluaran yang dihasilkan oleh *software MATLAB* adalah aturan “IF THEN”.

Bentuk aturan “IF THEN” yang terbentuk adalah:

```
tree75=
Decision tree for classification
1  if x2<288 then node 2 elseif x2>=288 then node 3 else
Lancar
2  if x5<0.496913 then node 4 elseif x5>=0.496913 then node
5 else Lancar
3  if x3<3.265e+008 then node 6 elseif x3>=3.265e+008 then
node 7 else Macet
4  class = Macet
5  if x1<8.75e+007 then node 8 elseif x1>=8.75e+007 then
node 9 else Lancar
6  if x1<2.6e+008 then node 10 elseif x1>=2.6e+008 then node
11 else Macet
7  class = Macet
8  class = Lancar
9  if x5<0.654743 then node 12 elseif x5>=0.654743 then node
13 else Lancar
10 class = Macet
11 class = Lancar
12 if x4<3.9e+006 then node 14 elseif x4>=3.9e+006 then node
15 else Lancar
13 if x2<270 then node 16 elseif x2>=270 then node 17 else
Lancar
14 if x1<1.746e+008 then node 18 elseif x1>=1.746e+008 then
node 19 else Lancar
15 class = Lancar
16 if x4<3.8113e+006 then node 20 elseif x4>=3.8113e+006
then node 21 else Lancar
17 class = Lancar
18 if x3<2.59921e+008 then node 22 elseif x3>=2.59921e+008
then node 23 else Lancar
19 class = Macet
```

```
20  if x4<3.79352e+006 then node 24 elseif x4>=3.79352e+006
then node 25 else Lancar
21  class = Lancar
22  if x4<2.80278e+006 then node 26 elseif x4>=2.80278e+006
then node 27 else Lancar
23  class = Lancar
24  if x5<0.799784 then node 28 elseif x5>=0.799784 then node
29 else Lancar
25  class = Macet
26  class = Macet
27  class = Lancar
28  class = Lancar
29  if x4<1.99954e+006 then node 30 elseif x4>=1.99954e+006
then node 31 else Lancar
30  if x4<1.93519e+006 then node 32 elseif x4>=1.93519e+006
then node 33 else Lancar
31  class = Lancar
32  class = Lancar
33  class = Macet
```



Gambar 3.3 Model *Decision Tree* 75%

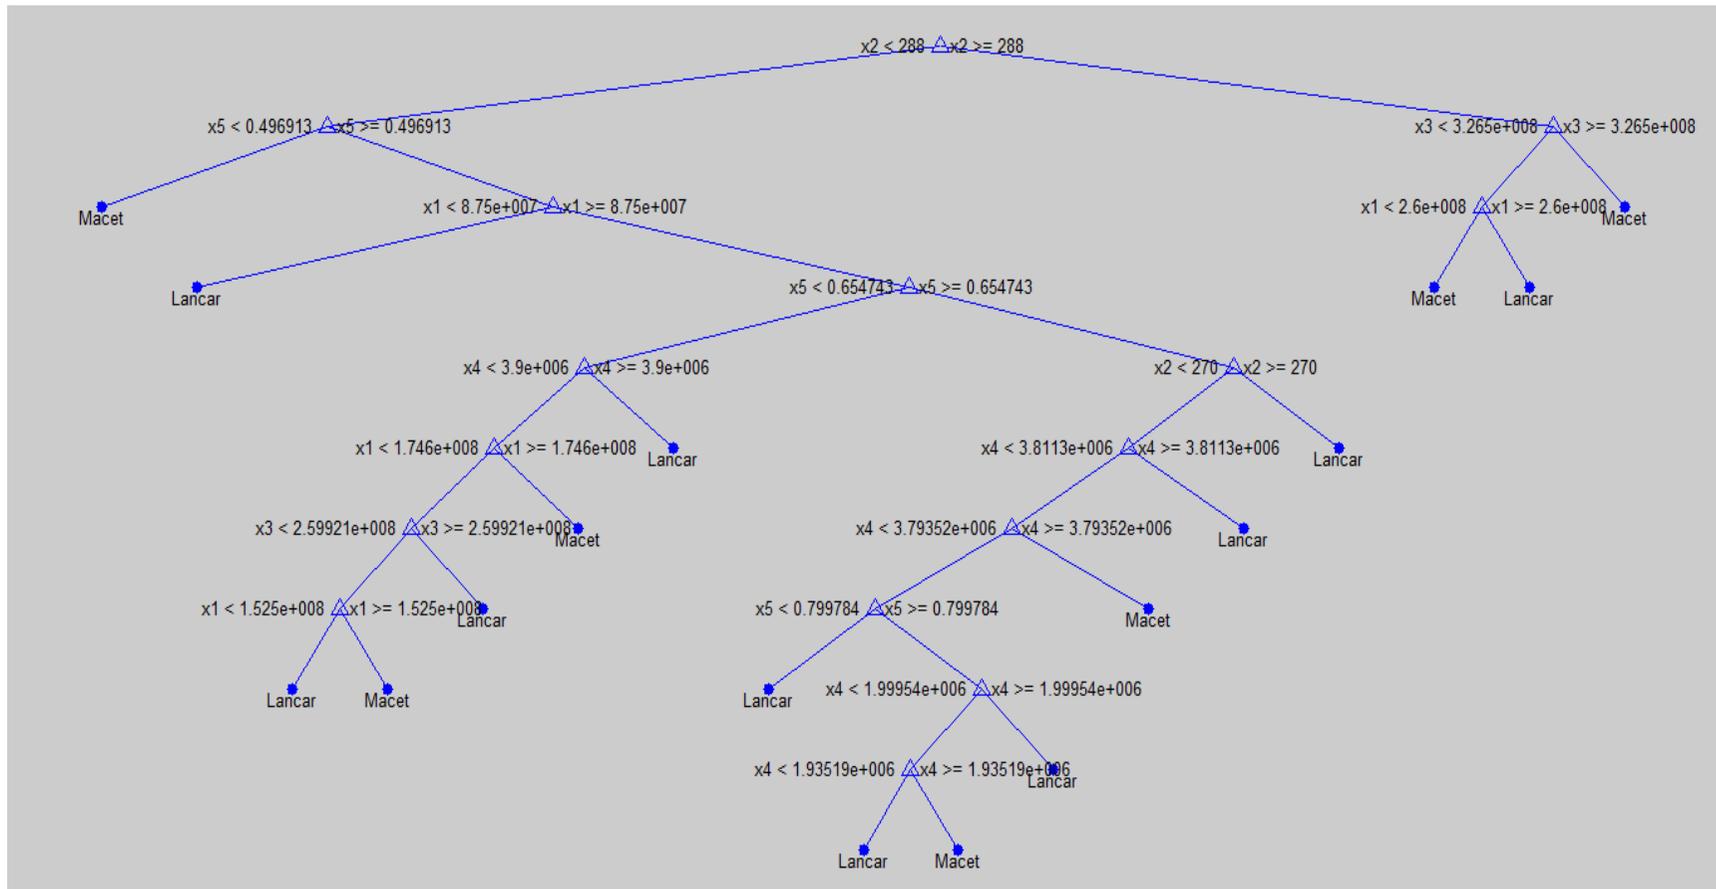
Gambar 3.3 di atas merupakan hasil penyusunan *decision tree* dengan komposisi 75% data *training* dan 25% data *testing* yang dihasilkan oleh *software* MATLAB.

Model *decision tree* kedua yang dibuat adalah *decision tree* dengan komposisi 80% data *training* dan 20% data *testing*. Model *decision tree* yang didapat untuk komposisi ini terdiri dari lima variabel *predictor* yang digunakan, 16 simpul terminal, dan 17 simpul daun. Bentuk dari *decision tree* 80%-20% ditampilkan pada Gambar 3.4.

Bentuk aturan “IF THEN” yang terbentuk adalah:

```
tree80 =
Decision tree for classification
1  if x2<288 then node 2 elseif x2>=288 then node 3 else
Lancar
2  if x5<0.496913 then node 4 elseif x5>=0.496913 then node
5 else Lancar
3  if x3<3.265e+008 then node 6 elseif x3>=3.265e+008 then
node 7 else Macet
4  class = Macet
5  if x1<8.75e+007 then node 8 elseif x1>=8.75e+007 then
node 9 else Lancar
6  if x1<2.6e+008 then node 10 elseif x1>=2.6e+008 then node
11 else Macet
7  class = Macet
8  class = Lancar
9  if x5<0.654743 then node 12 elseif x5>=0.654743 then node
13 else Lancar
10 class = Macet
11 class = Lancar
12 if x4<3.9e+006 then node 14 elseif x4>=3.9e+006 then node
15 else Lancar
13 if x2<270 then node 16 elseif x2>=270 then node 17 else
Lancar
14 if x1<1.746e+008 then node 18 elseif x1>=1.746e+008 then
node 19 else Lancar
15 class = Lancar
16 if x4<3.8113e+006 then node 20 elseif x4>=3.8113e+006
then node 21 else Lancar
17 class = Lancar
18 if x3<2.59921e+008 then node 22 elseif x3>=2.59921e+008
then node 23 else Lancar
```

```
19 class = Macet
20 if x4<3.79352e+006 then node 24 elseif x4>=3.79352e+006
then node 25 else Lancar
21 class = Lancar
22 if x1<1.525e+008 then node 26 elseif x1>=1.525e+008 then
node 27 else Lancar
23 class = Lancar
24 if x5<0.799784 then node 28 elseif x5>=0.799784 then node
29 else Lancar
25 class = Macet
26 class = Lancar
27 class = Macet
28 class = Lancar
29 if x4<1.99954e+006 then node 30 elseif x4>=1.99954e+006
then node 31 else Lancar
30 if x4<1.93519e+006 then node 32 elseif x4>=1.93519e+006
then node 33 else Lancar
31 class = Lancar
32 class = Lancar
33 class = Macet
```



Gambar 3.4 Model *Decision Tree* 80%

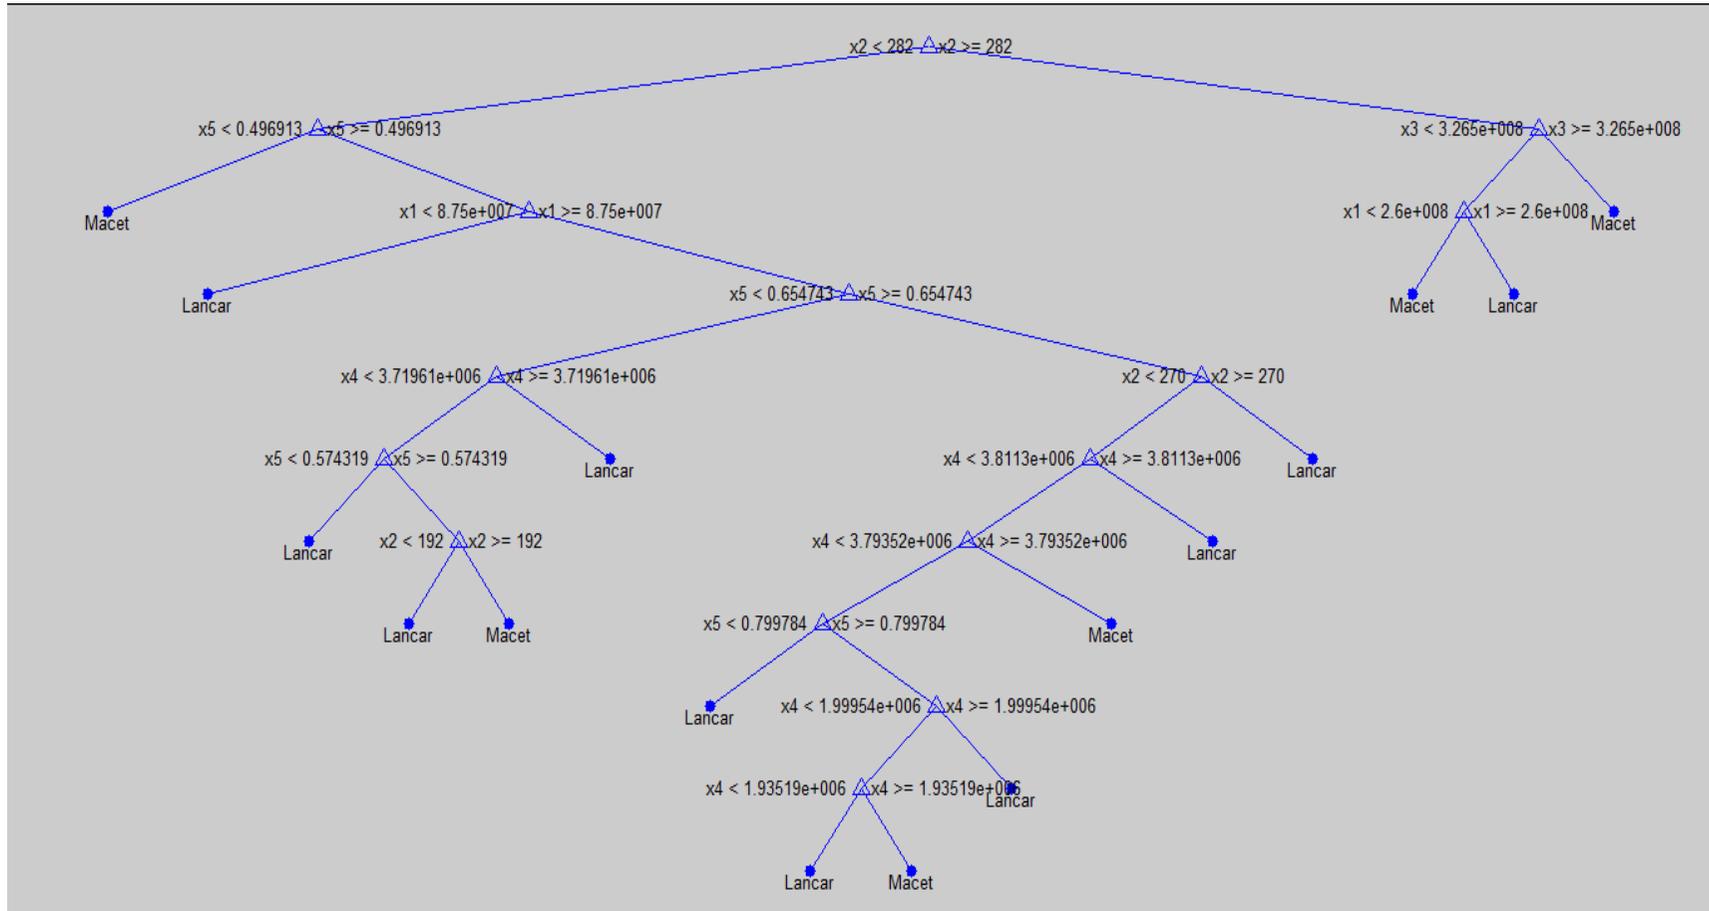
Gambar 3.4 di atas merupakan hasil penyusunan *decision tree* dengan komposisi 80% data *training* dan 20% data *testing* yang dihasilkan oleh *software* MATLAB.

Model *decision tree* ketiga yang dibuat adalah *decision tree* dengan komposisi 85% data *training* dan 15% data *testing*. Model *decision tree* yang didapat untuk komposisi ini terdiri dari lima variabel *predictor* yang digunakan, 15 simpul terminal, dan 16 simpul daun. Bentuk dari *decision tree* 85%-15% ditampilkan pada Gambar 3.5.

Bentuk aturan “IF THEN” yang terbentuk adalah:

```
tree85 =
Decision tree for classification
1  if x2<282 then node 2 elseif x2>=282 then node 3 else
Lancar
2  if x5<0.496913 then node 4 elseif x5>=0.496913 then node
5 else Lancar
3  if x3<3.265e+008 then node 6 elseif x3>=3.265e+008 then
node 7 else Macet
4  class = Macet
5  if x1<8.75e+007 then node 8 elseif x1>=8.75e+007 then
node 9 else Lancar
6  if x1<2.6e+008 then node 10 elseif x1>=2.6e+008 then node
11 else Macet
7  class = Macet
8  class = Lancar
9  if x5<0.654743 then node 12 elseif x5>=0.654743 then node
13 else Lancar
10 class = Macet
11 class = Lancar
12 if x4<3.71961e+006 then node 14 elseif x4>=3.71961e+006
then node 15 else Lancar
13 if x2<270 then node 16 elseif x2>=270 then node 17 else
Lancar
14 if x5<0.574319 then node 18 elseif x5>=0.574319 then node
19 else Lancar
15 class = Lancar
16 if x4<3.8113e+006 then node 20 elseif x4>=3.8113e+006
then node 21 else Lancar
17 class = Lancar
18 class = Lancar
```

```
19  if x2<192 then node 22 elseif x2>=192 then node 23 else
Macet
20  if x4<3.79352e+006 then node 24 elseif x4>=3.79352e+006
then node 25 else Lancar
21  class = Lancar
22  class = Lancar
23  class = Macet
24  if x5<0.799784 then node 26 elseif x5>=0.799784 then node
27 else Lancar
25  class = Macet
26  class = Lancar
27  if x4<1.99954e+006 then node 28 elseif x4>=1.99954e+006
then node 29 else Lancar
28  if x4<1.93519e+006 then node 30 elseif x4>=1.93519e+006
then node 31 else Lancar
29  class = Lancar
30  class = Lancar
31  class = Macet
```



Gambar 3.5 Model *Decision Tree* 85%

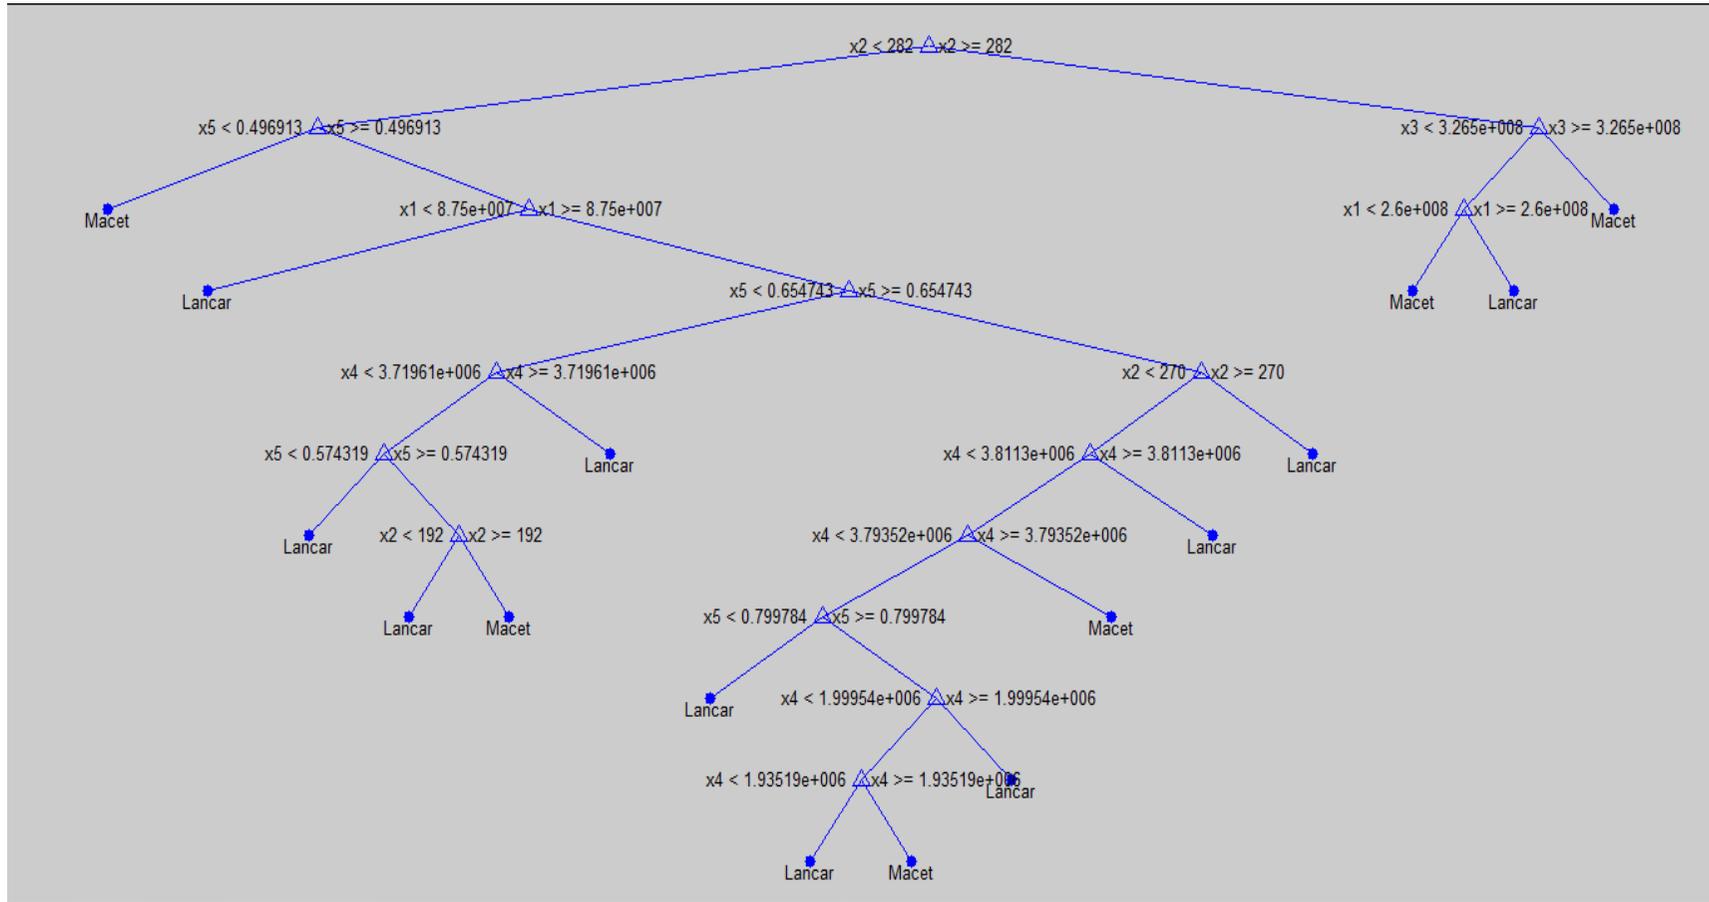
Gambar 3.5 di atas merupakan hasil penyusunan *decision tree* dengan komposisi 85% data *training* dan 15% data *testing* yang dihasilkan oleh *software* MATLAB.

Model *decision tree* keempat yang dibuat adalah *decision tree* dengan komposisi 90% data *training* dan 10% data *testing*. Model *decision tree* yang didapat untuk komposisi ini terdiri dari lima variabel *predictor* yang digunakan, 15 simpul terminal, dan 16 simpul daun. Bentuk dari *decision tree* 90%-10% ditampilkan pada Gambar 3.6.

Bentuk aturan “IF THEN” yang terbentuk adalah:

```
tree90 =
Decision tree for classification
1  if Tenor<282 then node 2 elseif Tenor>=282 then node 3
else Lancar
2  if Proporsi Pembiayaan<0.496913 then node 4 elseif
Proporsi Pembiayaan>=0.496913 then node 5 else Lancar
3  if Agunan<3.265e+008 then node 6 elseif Agunan>=3.265e+008
then node 7 else Macet
4  class = Macet
5  if Nominal Kredit<8.75e+007 then node 8 elseif Nominal
Kredit>=8.75e+007 then node 9 else Lancar
6  if Nominal Kredit<2.6e+008 then node 10 elseif Nominal
Kredit>=2.6e+008 then node 11 else Macet
7  class = Macet
8  class = Lancar
9  if Proporsi Pembiayaan<0.654743 then node 12 elseif
Proporsi Pembiayaan>=0.654743 then node 13 else Lancar
10 class = Macet
11 class = Lancar
12  if Pendapatan<3.71961e+006 then node 14 elseif
Pendapatan>=3.71961e+006 then node 15 else Lancar
13  if Tenor<270 then node 16 elseif Tenor>=270 then node 17
else Lancar
14  if Proporsi Pembiayaan<0.574319 then node 18 elseif
Proporsi Pembiayaan>=0.574319 then node 19 else Lancar
15 class = Lancar
16  if Pendapatan<3.8113e+006 then node 20 elseif
Pendapatan>=3.8113e+006 then node 21 else Lancar
17 class = Lancar
18 class = Lancar
```

```
19  if Tenor<192 then node 22 elseif Tenor>=192 then node 23
else Macet
20    if Pendapatan<3.79352e+006 then node 24 elseif
Pendapatan>=3.79352e+006 then node 25 else Lancar
21  class = Lancar
22  class = Lancar
23  class = Macet
24  if Proporsi Pembiayaan<0.799784 then node 26 elseif
Proporsi Pembiayaan>=0.799784 then node 27 else Lancar
25  class = Macet
26  class = Lancar
27    if Pendapatan<1.99954e+006 then node 28 elseif
Pendapatan>=1.99954e+006 then node 29 else Lancar
28    if Pendapatan<1.93519e+006 then node 30 elseif
Pendapatan>=1.93519e+006 then node 31 else Lancar
29  class = Lancar
30  class = Lancar
31  class = Macet
```



Gambar 3.6 Model *Decision Tree* 90%

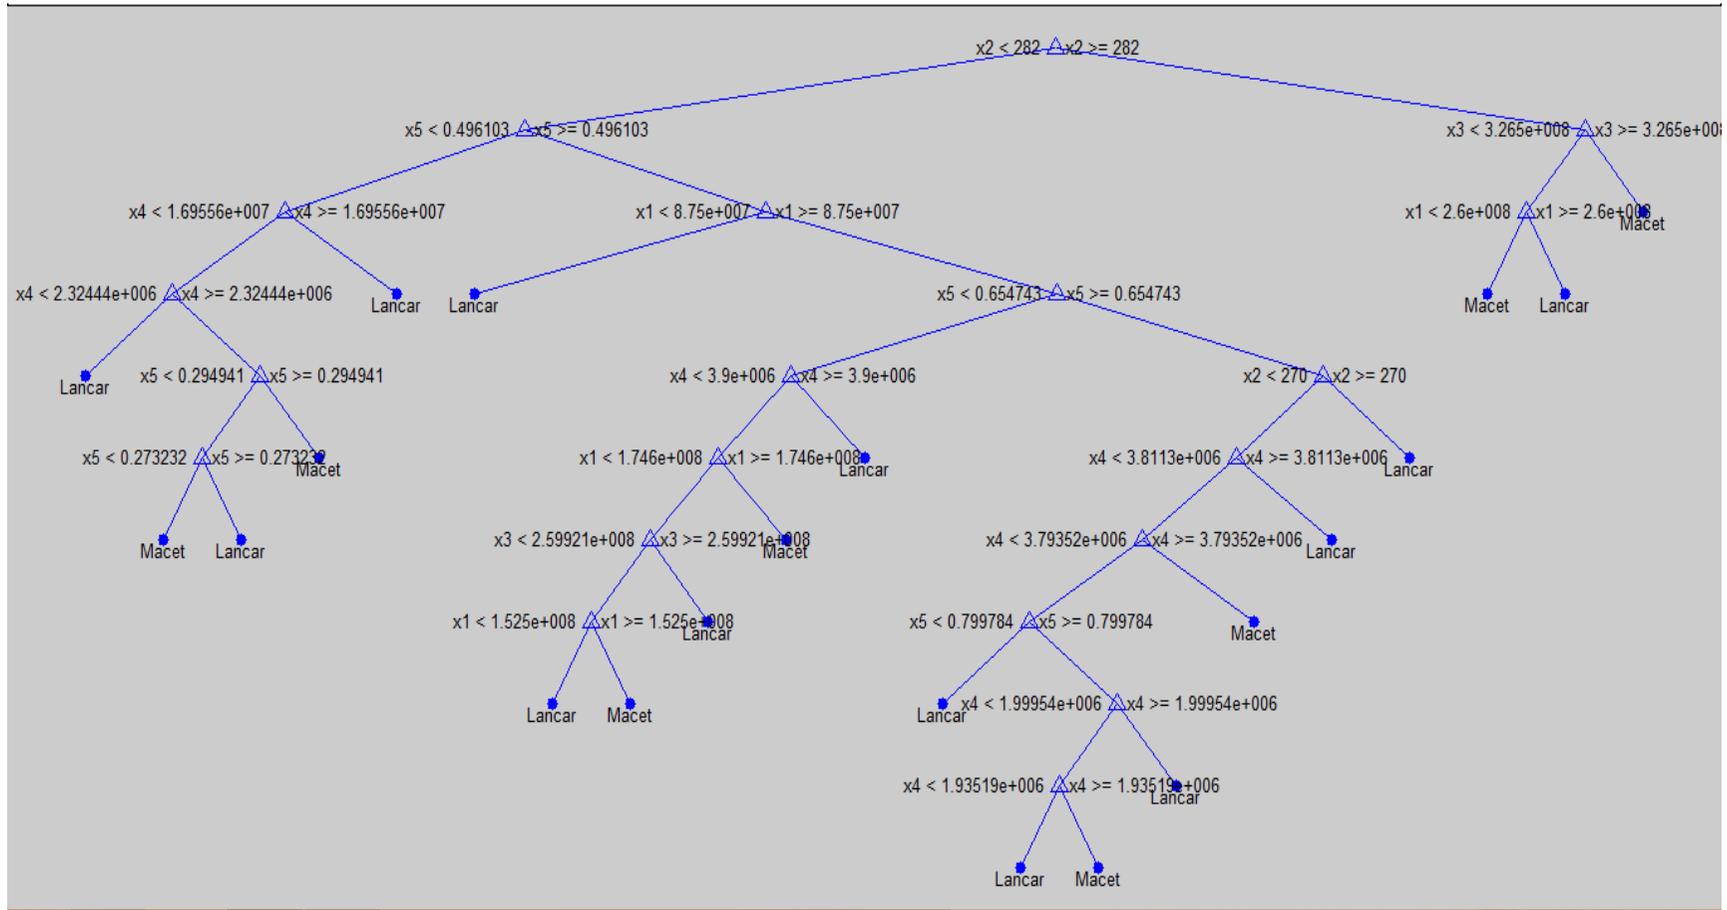
Gambar 3.6 di atas merupakan hasil penyusunan *decision tree* dengan komposisi 90% data *training* dan 10% data *testing* yang dihasilkan oleh *software* MATLAB.

Model *decision tree* kelima yang dibuat adalah *decision tree* dengan komposisi 95% data *training* dan 5% data *testing*. Model *decision tree* yang didapat untuk komposisi ini terdiri dari lima variabel *predictor* yang digunakan, 20 simpul terminal, dan 21 simpul daun. Bentuk dari *decision tree* 95%-5% ditampilkan pada Gambar 3.7.

Bentuk aturan “IF THEN” yang terbentuk adalah:

```
tree95 =
Decision tree for classification
1  if x2<282 then node 2 elseif x2>=282 then node 3 else
Lancar
2  if x5<0.496103 then node 4 elseif x5>=0.496103 then node
5 else Lancar
3  if x3<3.265e+008 then node 6 elseif x3>=3.265e+008 then
node 7 else Macet
4  if x4<1.69556e+007 then node 8 elseif x4>=1.69556e+007
then node 9 else Macet
5  if x1<8.75e+007 then node 10 elseif x1>=8.75e+007 then
node 11 else Lancar
6  if x1<2.6e+008 then node 12 elseif x1>=2.6e+008 then node
13 else Macet
7  class = Macet
8  if x4<2.32444e+006 then node 14 elseif x4>=2.32444e+006
then node 15 else Macet
9  class = Lancar
10 class = Lancar
11 if x5<0.654743 then node 16 elseif x5>=0.654743 then node
17 else Lancar
12 class = Macet
13 class = Lancar
14 class = Lancar
15 if x5<0.294941 then node 18 elseif x5>=0.294941 then node
19 else Macet
16 if x4<3.9e+006 then node 20 elseif x4>=3.9e+006 then node
21 else Lancar
17 if x2<270 then node 22 elseif x2>=270 then node 23 else
Lancar
```

```
18 if x5<0.273232 then node 24 elseif x5>=0.273232 then node
25 else Macet
19 class = Macet
20 if x1<1.746e+008 then node 26 elseif x1>=1.746e+008 then
node 27 else Lancar
21 class = Lancar
22 if x4<3.8113e+006 then node 28 elseif x4>=3.8113e+006
then node 29 else Lancar
23 class = Lancar
24 class = Macet
25 class = Lancar
26 if x3<2.59921e+008 then node 30 elseif x3>=2.59921e+008
then node 31 else Lancar
27 class = Macet
28 if x4<3.79352e+006 then node 32 elseif x4>=3.79352e+006
then node 33 else Lancar
29 class = Lancar
30 if x1<1.525e+008 then node 34 elseif x1>=1.525e+008 then
node 35 else Lancar
31 class = Lancar
32 if x5<0.799784 then node 36 elseif x5>=0.799784 then node
37 else Lancar
33 class = Macet
34 class = Lancar
35 class = Macet
36 class = Lancar
37 if x4<1.99954e+006 then node 38 elseif x4>=1.99954e+006
then node 39 else Lancar
38 if x4<1.93519e+006 then node 40 elseif x4>=1.93519e+006
then node 41 else Lancar
39 class = Lancar
40 class = Lancar
41 class = Macet
```



Gambar 3.7 Model *Decision Tree* 95%

Gambar 3.7 di atas merupakan hasil penyusunan *decision tree* dengan komposisi 95% data *training* dan 5% data *testing* yang dihasilkan oleh *software* MATLAB

- Evaluasi Model *Decision Tree*

Model *Decision Tree* yang telah dibentuk selanjutnya dilakukan evaluasi untuk mengetahui tingkat akurasi yang dihasilkan. Metode pengukuran akurasi yang dapat digunakan untuk mengevaluasi model *decision tree* adalah matriks konfusius. Skenario yang dilakukan adalah mengukur keakuratan model *decision tree* dalam memprediksi variabel *predictor* pada kelompok data *training* dan memprediksi variabel *predictor* pada kelompok data *testing*.

- Evaluasi Model *Decision Tree* (75%-25%)

Tabel 3.18 Hasil Prediksi *Tree75* untuk Data *Testing*

		Aktual		
		Lancar	Macet	Total
Prediksi	Lancar	201	2	203
	Macet	1	23	24
Total		202	25	227

*Probability of Detection* (POD), mengukur ketepatan prediksi (positif). Nilai POD berkisar dari nol hingga satu. POD bernilai satu bila secara tepat memprediksi kejadian “Ya”.

$$POD = \frac{a}{a + c}$$

$$POD = \frac{201}{201 + 1}$$

$$POD = 99.50\%$$

*True Negative Rate* (TNR), mengukur ketepatan prediksi (negatif). Nilai TNR berkisar dari nol hingga satu. TNR bernilai satu bila secara tepat memprediksi “Tidak”.

$$TNR = \frac{d}{d + b}$$

$$TNR = \frac{23}{23 + 2}$$

$$TNR = 92\%$$

*Overall Accuracy* (OA), mengukur ketepatan prediksi secara keseluruhan. Nilai OA bernilai satu apabila secara tepat memprediksi kejadian “Ya” dan “Tidak”.

$$OA = \frac{a + d}{a + b + c + d}$$

$$OA = \frac{201 + 23}{201 + 2 + 1 + 23}$$

$$OA = 98,68\%$$

Tabel 3.19 Hasil Prediksi *Tree75* untuk Data *Training*

		Aktual		
		Lancar	Macet	Total
Prediksi	Lancar	557	6	563
	Macet	11	111	122
Total		568	117	685

Perhitungan nilai POD model *tree75* untuk data *training*:

$$POD = \frac{a}{a + c}$$

$$POD = \frac{557}{557 + 11}$$

$$POD = 98,06\%$$

Perhitungan nilai TNR model *tree75* untuk data *training*:

$$TNR = \frac{d}{d + b}$$

$$TNR = \frac{111}{111 + 6}$$

$$TNR = 94,87\%$$

Perhitungan nilai OA model *tree75* untuk data *training*:

$$OA = \frac{a + d}{a + b + c + d}$$

$$OA = \frac{557 + 111}{557 + 11 + 6 + 111}$$

$$OA = 97,52\%$$

- Evaluasi Model *Decision Tree* (80%-20%)

Tabel 3.20 Hasil Prediksi *Tree80* untuk Data *Testing*

		Aktual		
		Lancar	Macet	Total
Prediksi	Lancar	163	2	165
	Macet	1	16	17
Total		164	18	182

Perhitungan nilai POD model *tree80* untuk data *testing*:

$$POD = \frac{a}{a + c}$$

$$POD = \frac{163}{163 + 1}$$

$$POD = 99,39\%$$

Perhitungan nilai TNR model *tree80* untuk data *testing*:

$$TNR = \frac{d}{d + b}$$

$$TNR = \frac{16}{16 + 2}$$

$$TNR = 88,88\%$$

Perhitungan nilai OA model *tree80* untuk data *testing*:

$$OA = \frac{a + d}{a + b + c + d}$$

$$OA = \frac{163 + 16}{163 + 1 + 2 + 16}$$

$$OA = 98,35\%$$

Tabel 3.21 Hasil Prediksi *Tree80* untuk Data *Training*

		Aktual		
		Lancar	Macet	Total
Prediksi	Lancar	597	4	601
	Macet	13	116	129
Total		610	120	730

Perhitungan nilai POD model *tree80* untuk data *training*:

$$POD = \frac{a}{a + c}$$

$$POD = \frac{597}{597 + 13}$$

$$POD = 97,87\%$$

Perhitungan nilai TNR model *tree80* untuk data *training*:

$$TNR = \frac{d}{d + b}$$

$$TNR = \frac{116}{116 + 4}$$

$$TNR = 96,66\%$$

Perhitungan nilai OA model *tree80* untuk data *training*:

$$OA = \frac{a + d}{a + b + c + d}$$

$$OA = \frac{597 + 116}{597 + 13 + 24 + 16}$$

$$OA = 97,67\%$$

- Evaluasi Model *Decision Tree* (85%-15%)

Tabel 3.22 Hasil Prediksi *Tree85* untuk Data *Testing*

		Aktual		
		Lancar	Macet	Total
Prediksi	Lancar	99	2	101
	Macet	0	11	11
Total		99	13	112

Perhitungan nilai POD model *tree85* untuk data *testing*:

$$POD = \frac{a}{a + c}$$

$$POD = \frac{99}{99 + 0}$$

$$POD = 100\%$$

Perhitungan nilai TNR model *tree85* untuk data *testing*:

$$TNR = \frac{d}{d + b}$$

$$TNR = \frac{11}{11 + 2}$$

$$TNR = 84,62\%$$

Perhitungan nilai OA model *tree85* untuk data *testing*:

$$OA = \frac{a + d}{a + b + c + d}$$

$$OA = \frac{99 + 11}{99 + 0 + 2 + 11}$$

$$OA = 98,21\%$$

Tabel 3.23 Hasil Prediksi *Tree85* untuk Data *Training*

		Aktual		
		Lancar	Macet	Total
Prediksi	Lancar	662	3	665
	Macet	15	120	135
Total		677	123	800

Perhitungan nilai POD model *tree85* untuk data *training*:

$$POD = \frac{a}{a + c}$$

$$POD = \frac{662}{662 + 15}$$

$$POD = 97,78\%$$

Perhitungan nilai TNR model *tree85* untuk data *training*:

$$TNR = \frac{d}{d + b}$$

$$TNR = \frac{120}{120 + 3}$$

$$TNR = 97,56\%$$

Perhitungan nilai OA model *tree85* untuk data *training*:

$$OA = \frac{a + d}{a + b + c + d}$$

$$OA = \frac{662 + 120}{662 + 15 + 3 + 120}$$

$$OA = 97,75\%$$

- Evaluasi Model *Decision Tree* (90%-10%)

Tabel 3.24 Hasil Prediksi *Tree90* untuk Data *Testing*

		Aktual		
		Lancar	Macet	Total
Prediksi	Lancar	81	2	83
	Macet	0	9	9
Total		81	11	92

Perhitungan nilai POD model *tree90* untuk data *testing*:

$$POD = \frac{a}{a + c}$$

$$POD = \frac{81}{81 + 0}$$

$$POD = 100\%$$

Perhitungan nilai TNR model *tree90* untuk data *testing*:

$$TNR = \frac{d}{d + b}$$

$$TNR = \frac{9}{9 + 2}$$

$$TNR = 81,81\%$$

Perhitungan nilai OA model *tree90* untuk data *testing*:

$$OA = \frac{a + d}{a + b + c + d}$$

$$OA = \frac{81 + 9}{81 + 0 + 2 + 9}$$

$$OA = 97,83\%$$

Tabel 3.25 Hasil Prediksi *Tree90* untuk Data *Training*

		Aktual		
		Lancar	Macet	Total
Prediksi	Lancar	680	3	683
	Macet	15	122	137
Total		695	125	820

Perhitungan nilai POD model *tree90* untuk data *training*:

$$POD = \frac{a}{a + c}$$

$$POD = \frac{680}{680 + 15}$$

$$POD = 97,84\%$$

Perhitungan nilai TNR model *tree90* untuk data *training*:

$$TNR = \frac{d}{d + b}$$

$$TNR = \frac{122}{122 + 3}$$

$$TNR = 97,60\%$$

Perhitungan nilai OA model *tree90* untuk data *training*:

$$OA = \frac{a + d}{a + b + c + d}$$

$$OA = \frac{680 + 122}{680 + 15 + 3 + 122}$$

$$OA = 97,80\%$$

- Evaluasi Model *Decision Tree* (95%-5%)

Tabel 3.26 Hasil Prediksi *Tree95* untuk Data *Testing*

		Aktual		
		Lancar	Macet	Total
Prediksi	Lancar	40	0	40
	Macet	1	5	6
Total		41	5	46

Perhitungan nilai POD model *tree95* untuk data *testing*:

$$POD = \frac{a}{a + c}$$

$$POD = \frac{40}{40 + 1}$$

$$POD = 97,56\%$$

Perhitungan nilai TNR model *tree95* untuk data *testing*:

$$TNR = \frac{d}{d + b}$$

$$TNR = \frac{5}{5 + 0}$$

$$TNR = 100\%$$

Perhitungan nilai OA model *tree95* untuk data *testing*:

$$OA = \frac{a + d}{a + b + c + d}$$

$$OA = \frac{40 + 5}{40 + 1 + 0 + 5}$$

$$OA = 97,82\%$$

Tabel 3.27 Hasil Prediksi *Tree95* untuk Data *Training*

		Aktual		
		Lancar	Macet	Total
Prediksi	Lancar	724	2	726
	Macet	16	124	140
Total		740	126	866

Perhitungan nilai POD model *tree95* untuk data *training*:

$$POD = \frac{a}{a + c}$$

$$POD = \frac{724}{724 + 16}$$

$$POD = 97,84\%$$

Perhitungan nilai TNR model *tree95* untuk data *training*:

$$TNR = \frac{d}{d + b}$$

$$TNR = \frac{124}{124 + 2}$$

$$TNR = 98,41\%$$

Perhitungan nilai OA model *tree95* untuk data *training*:

$$OA = \frac{a + d}{a + b + c + d}$$

$$OA = \frac{724 + 124}{724 + 16 + 2 + 124}$$

$$OA = 97,92\%$$

- Pemilihan Model *Decision Tree* Optimal

Hasil evaluasi model *decision tree* ditampilkan pada Tabel 3.28 berikut:

Tabel 3.28 Hasil Evaluasi Model *Decision Tree*

Komposisi <i>Decision Tree</i>	Data <i>Training</i>			Data <i>Testing</i>		
	POD	TNR	OA	POD	TNR	OA
(75%-25%)	98,06%	94,87%	97,52%	99,50%	92,00%	98,68%
(80%-20%)	97,87%	96,66%	97,67%	99,39%	88,88%	98,35%
(85%-15%)	97,78%	97,56%	97,75%	100,00%	84,62%	98,21%
(90%-10%)	97,78%	97,56%	97,75%	100,00%	81,81%	97,83%
(95%-5%)	97,84%	98,41%	97,92%	97,56%	100,00%	97,82%

Pemilihan model *decision tree* optimal dilakukan dengan beberapa pertimbangan. Pertimbangan pertama adalah besar nilai performansi POD dan TNR pada data *testing*, hal ini dikarenakan suatu model prediksi harus dapat dengan baik memprediksi kejadian ya dan tidak dengan baik. Nilai POD menunjukkan kapabilitas model dalam memprediksi kejadian ya dengan tepat, sedangkan TNR menunjukkan kapabilitas model dalam memprediksi kejadian tidak dengan tepat. Sehingga model yang memiliki nilai masing-masing POD dan TNR yang tinggi merepresentasikan kapabilitasnya dalam memprediksi suatu kejadian dengan baik. Pertimbangan kedua adalah komposisi data *training* dan data *testing* dalam menyusun suatu model, apabila ditemukan dua model yang memiliki nilai POD dan TNR yang sama-sama besar maka penentuan model optimal dilakukan dengan dasar pertimbangan proporsi data *training* yang digunakan untuk menyusun model tersebut. Model yang memiliki proporsi data *training* yang lebih kecil menunjukkan kapabilitas prediksi data atau kejadian baru dengan baik, dikarenakan proporsi data yang digunakan untuk menyusun model lebih sedikit dan banyak data diluar model yang tidak dikenali. Pertimbangan ketiga adalah target atau kriteria tertentu yang ditetapkan oleh suatu perusahaan sebagai batasan performansi model tersebut.

Berdasarkan tiga pertimbangan tersebut, dari Tabel 3.28 dapat dilihat bahwa model *decision tree* dengan komposisi data *training* dan data *testing* 95%-

5% memiliki nilai POD dan TNR yang relatif lebih besar dibanding model yang lain, dan telah memenuhi target perusahaan yang menetapkan akurasi minimum 95%.

### 3.3.2 Penyusunan Model *Inspection Game*

Pada subbab ini dijelaskan mengenai tahapan pembuatan model utilitas dan disutilitas *player* pada permasalahan kredit macet dan strukturisasi model *inspection game* dalam menentukan strategi optimal yang dapat menyelesaikan masalah kredit macet.

- Formulasi Model Konseptual

Perancangan model konseptual dari model *inspection game* dilakukan dengan mengidentifikasi komponen-komponen penyusun *game*. Komponen pertama dari sebuah model *game* adalah *player* yang terlibat dalam *game* yang terjadi. *Player* pada model *game* akan menjadi pengambil keputusan dari alternatif strategi yang ada. Asumsi dasar didalam *game theory* adalah semua *player* bersifat rasional, yakni bertujuan untuk memperoleh keuntungan sebesar-besarnya. Pada kasus persoalan kredit macet, *player* yang terlibat adalah bank dan nasabah, dimana didalam model *inspection game* pihak bank berperan sebagai *enforcer* sedangkan pihak nasabah berperan sebagai *offender*. *Enforcer* adalah *player* yang memiliki kuasa lebih dalam melakukan penerapan kebijakan, sedangkan *offender* adalah *player* yang cenderung pasif menerima kebijakan tetapi masih berusaha untuk menghindari kerugian. Komponen kedua adalah kombinasi strategi yang dimiliki oleh tiap *player*. Dalam model *inspection game* ini, *game* dilakukan secara potret atau *one shot game*, sehingga masing-masing *player* hanya memiliki dua strategi. Komponen ketiga adalah *payoff* untuk masing-masing *player* yang merupakan hasil konsekuensi skenario bertemunya strategi *i* dari *player* pertama dengan strategi *j* dari *player* kedua. Berdasarkan komponen-komponen yang telah teridentifikasi maka model konseptual untuk *game* permasalahan kredit macet dapat distrukturisasi. Tabel 3.29 menggambarkan model konseptual dari permasalahan kredit macet yang dialami oleh Bank. X.

Tabel 3.29 Model Konseptual *Inspection Game* Persoalan Kredit Macet

		Bank	
		Sanksi	Penghargaan
Nasabah	Macet	a1	b1
		a2	b2
	Lancar	c1	d1
		c2	d2

- a1 : *payoff* untuk nasabah dari skenario macet-sanksi
- b1 : *payoff* untuk nasabah dari skenario macet-penghargaan
- c1 : *payoff* untuk nasabah dari skenario lancar-sanksi
- d1 : *payoff* untuk nasabah dari skenario macet-penghargaan
- a2 : *payoff* untuk bank dari skenario macet-sanksi
- b2 : *payoff* untuk bank dari skenario macet-penghargaan
- c2 : *payoff* untuk bank dari skenario lancar-sanksi
- d2 : *payoff* untuk bank dari skenario macet-penghargaan

Setelah mendapatkan model konseptual *inspection game* dari permasalahan kredit macet, langkah selanjutnya adalah mengidentifikasi variabel-variabel penyusun *payoff* .Setiap *payoff* yang berada pada masing-masing sel memiliki variabel-variabel yang memengaruhi nilai dari *payoff* tersebut. Hubungan antar variabel-variabel yang memengaruhi nilai *payoff* dapat diidentifikasi dengan menganalisis deskripsi masalah yang terjadi pada permasalahan kredit macet. Berikut ini merupakan deskripsi permasalahan kredit macet.

- Pengambil Keputusan

Pengambil keputusan pada model *inspection game* merupakan *player* yang terlibat di dalam *game*. Pada permasalahan kredit macet, yang menjadi *decision maker* adalah nasabah dan atau bank.

- Objektif Keputusan

Objektif atau tujuan dari permasalahan ini adalah bagaimana bank dapat mengambilkan suatu kebijakan yang dapat meminimasi tendensi nasabah untuk melakukan kredit macet.

- Kriteria Pemilihan

Kriteria pemilihan keputusan pada permasalahan kredit macet adalah meminimumkan jumlah nasabah yang akan melakukan kredit macet dan memaksimalkan keuntungan dari pemberian kredit.

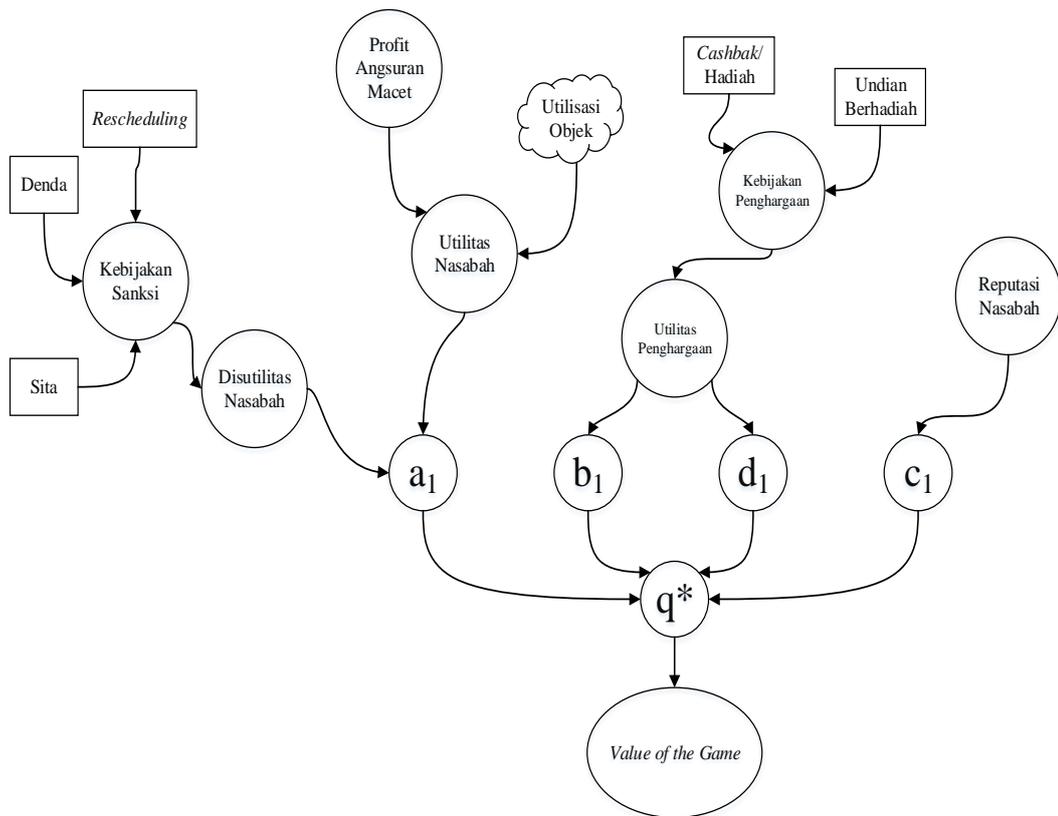
- Ukuran Performansi

Ukuran performansi yang digunakan pada permasalahan ini adalah jumlah nasabah yang melakukan kredit macet, keuntungan yang diperoleh nasabah, dan keuntungan yang diperoleh bank.

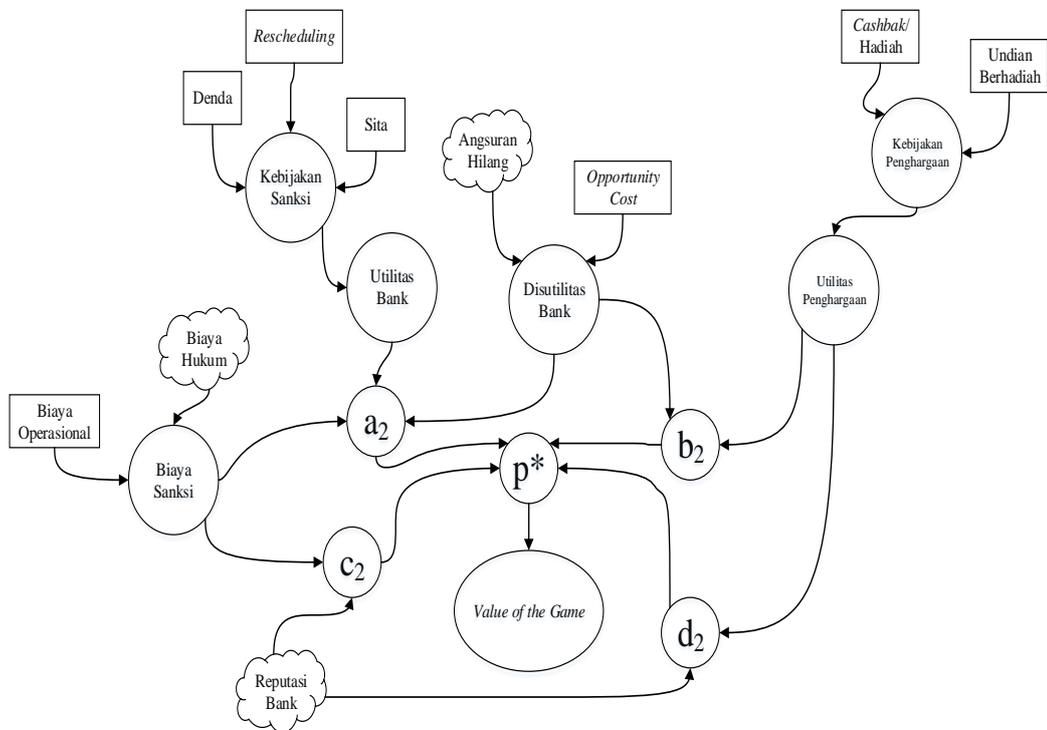
- Kontrol Masukan atau Alternatif Tindakan

Kontrol masukan dalam permasalahan ini adalah kebijakan sanksi dan kebijakan penghargaan yang dapat dilakukan oleh bank. Alternatif tindakan yang dapat dilakukan adalah penambahan atau pengurangan nilai sanksi dan penghargaan yang diberikan.

Deskripsi sistem dari permasalahan ini digambarkan dengan menggunakan *influence diagram*. Terdapat beberapa komponen pada *influence diagram* yaitu *input* tidak terkendali, *input* terkendali (*decision*), *output*, dan variabel sistem. Komponen-komponen tersebut saling dihubungkan dengan tanda panah dimana tanda panah memiliki arti bahwa komponen yang dituju dipengaruhi oleh komponen yang lainnya. Hubungan-hubungan antar variabel ini ditampilkan pada *influence diagram* yang terdapat pada Gambar 3.8 dan Gambar 3.9.



Gambar 3.8 Influence Diagram Payoff untuk Nasabah



Gambar 3.9 Influence Diagram Payoff untuk Bank

- Variabel Penyusun Model

Model konseptual dari *inspection game* yang telah dibentuk serta hubungan relasi antar variabel yang dijelaskan pada *influence diagram* didapatkan suatu formulasi yang dapat menentukan nilai dari masing-masing *payoff* pada tiap sel.

- Formulasi *Payoff* untuk Nasabah

Nilai-nilai *payoff* yang mungkin didapatkan nasabah pada model *inspection game* terdiri dari empat kemungkinan. *Payoff* pertama merupakan hasil dari skenario strategi macet yang dilakukan oleh nasabah dan diikuti dengan strategi sanksi oleh bank secara simultan. *Payoff* kedua merupakan hasil dari skenario strategi macet yang dilakukan oleh nasabah dan diikuti dengan penghargaan oleh bank secara simultan. *Payoff* ketiga merupakan hasil dari skenario strategi lancar yang dilakukan oleh nasabah dan diikuti dengan sanksi oleh bank secara simultan. *Payoff* keempat merupakan hasil dari skenario strategi lancar oleh nasabah dan diikuti dengan penghargaan oleh bank secara simultan. Berikut merupakan formulasi perhitungan *payoff* tiap sel:

- Skenario Macet-Sanksi

Pada penentuan model konseptual, *payoff* yang didapatkan oleh nasabah pada sel ini dinotasikan dengan  $a_1$ . Sedangkan pada *influence diagram* didapatkan suatu relasi besarnya  $a_1$  dipengaruhi oleh utilitas yang diperoleh nasabah ketika melakukan pembayaran secara macet ( $U_N$ ) dan disutilitas yang dialami oleh nasabah ketika bank melakukan sanksi ( $D_N$ ).

Formulasi yang didapatkan untuk menghitung besarnya  $a_1$  adalah:

$$a_1 = U_N - D_N \quad (3.04)$$

Selain itu didapatkan pula variabel-variabel yang memengaruhi nilai  $U_N$  dan  $D_N$ . Nilai  $U_N$  dipengaruhi oleh keuntungan yang didapatkan dari besar angsuran yang tidak terbayarkan ( $F$ ) dan juga utilisasi rumah yang menjadi agunan ( $S$ ). Sehingga didapatkan formulasi perhitungan  $U_N$  adalah:

$$U_N = F + S \quad (3.05)$$

Nilai F didapatkan dengan formulasi berikut:

$$F = A x \left[ \frac{(1+i)^t - 1}{i} \right] \quad (3.06)$$

- A : nilai angsuran  
 F : keuntungan dari angsuran yang tidak terbayarkan  
 i : presentase keuntungan yang didapat  
 t : lama waktu angsuran macet

Nilai S tidak memiliki formulasi khusus yang dapat mengaproksimasi besarnya, hal ini dikarenakan besar nilai utilisasi sangat tidak menentu tergantung pada tipe rumah, lokasi, tujuan utilisasi, dan banyak hal lain yang menjadikan S variabel tak terkontrol.

Nilai  $D_N$  dipengaruhi oleh kebijakan sanksi yang diberikan bank kepada nasabah. Alternatif kebijakan sanksi yang sering diterapkan oleh bank adalah: pengenaan denda dengan nominal tertentu (D), negosiasi *rescheduling* dengan memperbaharui tenor dan suku bunga (N), menyita agunan untuk dilelang atau dijual (M), dan melakukan *blacklist* (B). Menimbang beberapa alternatif kebijakan yang tersedia, maka formulasi nilai  $D_N$  yang didapat adalah:

$$D_N = \alpha D + \beta N + \delta M + B \quad (3.07)$$

$\alpha, \beta, \delta$  : 1 jika dilakukan, 0 jika tidak

Nilai D didapatkan dengan formulasi berikut:

$$D = (\sum_{t=1}^n d_t) x A \quad (3.08)$$

- d : tingkat denda  
 t : lama macet

A : angsuran

Nilai N didapatkan dengan formulasi berikut:

$$N = \frac{(H-PPxt)}{t_n} x(1 + i_n)^{t_n} \quad (3.09)$$

H : besar pinjaman

PP : pokok pinjaman

t : waktu pinjaman terbayarkan

$i_n$  : suku bunga baru

$t_n$  : jangka waktu baru

Nilai M didapatkan dengan formulasi berikut:

$$M = J + \sum_{t=1}^n A_t + K \quad (3.10)$$

J : nilai agunan

$A_t$  : angsuran ke-t

K : dampak psikologis

– Skenario Macet-Penghargaan

Pada penentuan model konseptual *payoff* yang didapatkan oleh nasabah pada sel ini dinotasikan dengan  $b_1$ . Sedangkan pada *influence diagram* didapatkan suatu relasi besarnya  $b_1$  dipengaruhi oleh utilitas yang diperoleh nasabah ketika melakukan pembayaran secara macet ( $U_N$ ) dan nilai hadiah yang diperoleh nasabah ( $P_N$ ). Formulasi yang didapatkan untuk menghitung besarnya  $b_1$  adalah:

$$b_1 = U_N + P_N \quad (3.11)$$

Nilai  $P_N$  dipengaruhi oleh kebijakan yang diambil oleh pihak bank. Alternatif kebijakan pemberian penghargaan yang biasa diterapkan pihak

bank adalah: undian berhadiah diakhir periode pembayaran (L) dan *cashback* (C). Berdasarkan variabel-variabel tersebut maka formulasi nilai  $P_N$  yang didapat adalah:

$$P_N = \varepsilon L + \sigma C \quad (3.12)$$

$\varepsilon, \sigma$  : 1 jika dilakukan, 0 jika tidak

– Skenario Lancar-Sanksi

Pada penentuan model konseptual *payoff* yang didapatkan oleh nasabah pada sel ini dinotasikan dengan  $c_1$ . Sedangkan pada *influence diagram* didapatkan suatu relasi besarnya  $c_1$  dipengaruhi oleh reputasi nasabah ketika dikenai sanksi ( $R_N$ ). Formulasi yang didapatkan untuk menghitung besarnya  $c_1$  adalah:

$$c_1 = R_N \quad (3.13)$$

– Skenario Lancar-Penghargaan

Pada penentuan model konseptual *payoff* yang didapatkan oleh nasabah pada sel ini dinotasikan dengan  $d_1$ . Sedangkan pada *influence diagram* didapatkan suatu relasi besarnya  $d_1$  dipengaruhi oleh nilai hadiah yang diperoleh nasabah ( $P_N$ ). Formulasi yang didapatkan untuk menghitung besarnya  $d_1$  adalah:

$$d_1 = P_N \quad (3.14)$$

○ Formulasi *Payoff* untuk Bank

Perhitungan nilai-nilai *payoff* untuk bank terdiri dari empat kemungkinan. Tiap-tiap *payoff* merupakan hasil yang dari skenario yang sama dengan penentuan *payoff* untuk nasabah. Skenario pertama merupakan skenario macet-sanksi, skenario kedua adalah macet-penghargaan, skenario ketiga adalah lancar-sanksi, dan skenario keempat adalah lancar-

penghargaan. Berikut merupakan formulasi perhitungan *payoff* untuk tiap skenario:

- Skenario Macet-Sanksi

Pada penentuan model konseptual *payoff* yang didapatkan oleh nasabah pada sel ini dinotasikan dengan  $a_2$ . Sedangkan pada *influence diagram* didapatkan suatu relasi besarnya  $a_2$  dipengaruhi oleh utilitas yang diperoleh bank ketika melakukan sanksi ( $U_B$ ), disutilitas yang dialami oleh bank ketika nasabah melakukan pembayaran macet ( $D_B$ ), dan biaya yang diperlukan bank untuk melakukan sanksi ( $C_B$ ). Formulasi yang didapatkan untuk menghitung besarnya  $a_2$  adalah:

$$a_2 = U_B - D_B - C_B \quad (3.15)$$

Selain itu didapatkan pula variabel-variabel yang memengaruhi nilai  $U_B$ ,  $D_B$ , dan  $C_B$ . Nilai  $U_B$  dipengaruhi oleh nilai denda yang dikumpulkan dari nasabah ( $D'$ ), nilai *rescheduling* ( $N'$ ), dan nilai agunan hasil sitaan ( $M'$ ). Sehingga didapatkan formulasi perhitungan  $U_B$  adalah:

$$U_B = \alpha D' + \beta N' + \delta M \quad (3.16)$$

$\alpha, \beta, \delta$  : 1 jika dilakukan, 0 jika tidak

Nilai  $D'$  didapatkan dengan formulasi berikut:

$$D' = D = (\sum_{t=1}^n d_t) x A \quad (3.17)$$

$d$  : tingkat denda

$t$  : lama macet

$A$  : angsuran

Nilai  $N'$  didapatkan dengan formulasi berikut:

$$N' = N = \frac{(H-PPxt)}{t_n} x (1 + i_n)^{t_n} \quad (3.18)$$

- H : besar pinjaman  
 PP : pokok pinjaman  
 t : waktu pinjaman terbayarkan  
 $i_n$  : suku bunga baru  
 $t_n$  : jangka waktu baru

Nilai  $M'$  didapatkan dengan formulasi berikut:

$$M' = J + \sum_{t=1}^n A_t \quad (3.19)$$

- J : nilai agunan  
 $A_t$  : angsuran ke-t

Nilai  $D_B$  dipengaruhi oleh besarnya nilai angsuran yang dibayar oleh nasabah ( $F'$ ) dan nilai kesempatan atau *opportunity cost* yang dapat dipergunakan bank untuk mencari keuntungan lain (OC). Sehingga didapatkan formulasi perhitungan  $D_B$  adalah:

$$D_B = F' + OC \quad (3.20)$$

Nilai  $F'$  didapatkan dengan formulasi berikut:

$$F' = F = A x \left[ \frac{(1+i)^t - 1}{i} \right] \quad (3.21)$$

- A : nilai angsuran  
 i : suku bunga yang ditetapkan  
 t : lama waktu angsuran macet

Nilai OC didapatkan dengan formulasi berikut:

$$OC = A x \left[ \frac{(1+i)^t - 1}{i'} \right] \quad (3.22)$$

- $i'$  : presentase keuntungan yang dapat diperoleh bank

Nilai  $C_B$  dipengaruhi oleh besar biaya operasional yang dikeluarkan oleh bank ( $B_o$ ) dan biaya untuk menempuh proses hukum ( $B_h$ ). Sehingga didapatkan formulasi perhitungan  $C_B$  adalah:

$$C_B = B_o + B_h \quad (3.23)$$

– Skenario Macet-Penghargaan

Pada penentuan model konseptual *payoff* yang didapatkan oleh nasabah pada sel ini dinotasikan dengan  $b_2$ . Sedangkan pada *influence diagram* didapatkan suatu relasi besarnya  $b_2$  dipengaruhi oleh disutilitas yang dialami oleh bank ketika nasabah melakukan pembayaran macet ( $D_B$ ) dan nilai hadiah yang diberikan pada nasabah ( $P_B$ ). Formulasi yang didapatkan untuk menghitung besarnya  $b_2$  adalah:

$$b_2 = -D_B - P_B \quad (3.24)$$

Nilai  $P_B$  dipengaruhi oleh kebijakan yang diambil oleh pihak bank. Alternatif kebijakan pemberian penghargaan yang biasa diterapkan pihak bank adalah: undian berhadiah diakhir periode pembayaran ( $L$ ) dan *cashback* ( $C$ ). Berdasarkan variabel-variabel tersebut maka formulasi nilai  $P_B$  yang didapat adalah:

$$P_B = P_N = \varepsilon L + \sigma C \quad (3.25)$$

$\varepsilon, \sigma$  : 1 jika dilakukan, 0 jika tidak

– Skenario Lancar-Sanksi

Pada penentuan model konseptual *payoff* yang didapatkan oleh nasabah pada sel ini dinotasikan dengan  $c_2$ . Sedangkan pada *influence diagram* didapatkan suatu relasi besarnya  $c_2$  dipengaruhi oleh reputasi bank ketika menjalankan kebijakan ( $R_B$ ) dan biaya yang diperlukan bank untuk

melakukan sanksi ( $C_B$ ). Formulasi yang didapatkan untuk menghitung besarnya  $c_2$  adalah:

$$c_2 = R_B - C_B \quad (3.26)$$

– Skenario Lancar-Penghargaan

Pada penentuan model konseptual *payoff* yang didapatkan oleh nasabah pada sel ini dinotasikan dengan  $d_2$ . Sedangkan pada *influence diagram* didapatkan suatu relasi besarnya  $d_2$  dipengaruhi oleh reputasi bank ketika menjalankan kebijakan ( $R_B$ ) dan nilai hadiah yang diberikan pada nasabah ( $P_B$ ). Formulasi yang didapatkan untuk menghitung besarnya  $d_2$  adalah:

$$d_2 = R_B - P_B \quad (3.27)$$

- Formulasi Distribusi Probabilitas Strategi

Tahap ini telah didapatkan model *inspection game* yang telah merepresentasikan persoalan kredit macet setelah mendapatkan variabel-variabel penyusun *payoff* untuk tiap skenario strategi. Tabel 3.30 merupakan model *inspection game* dari permasalahan kredit macet.

Tabel 3.30 Model *Inspection Game* Persoalan Kredit Macet

		Bank	
		Sanksi	Penghargaan
Nasabah	Macet	$U_N - D_N$ $U_B - D_B - C_B$	$U_N + P_N$ $-D_B - P_B$
	Lancar	$R_N$ $R_B - C_B$	$P_N$ $R_B - P_B$

Dengan adanya model *inspection game*, maka perhitungan distribusi probabilitas strategi yang digunakan oleh masing-masing *player* dapat dilakukan. Tsebelis (1989) menemukan formulasi probabilitas optimal yang akan digunakan oleh setiap *player*. Untuk *player* pertama probabilitas optimal dinotasikan dengan  $p^*$ , sedangkan untuk *player* kedua probabilitas

optimal dinotasikan dengan  $q^*$ . Berikut masing-masing penentuan probabilitas optimal:

Perhitungan  $p^*$ :

$$\begin{aligned}
 p^* &= \frac{d_2 - c_2}{a_2 - b_2 - c_2 + d_2} \\
 p^* &= \frac{(R_B - P_B) - (R_B - C_B)}{(U_B - D_B - C_B) - (-D_B - P_B) - (R_B - P_B) + (R_B - C_B)} \\
 p^* &= \frac{C_B - P_B}{U_B} \tag{3.28}
 \end{aligned}$$

Perhitungan  $q^*$ :

$$\begin{aligned}
 q^* &= \frac{d_1 - b_1}{a_1 - b_1 - c_1 + d_1} \\
 q^* &= \frac{(P_N) - (U_N - P_N)}{(U_N - D_N) - (U_N + P_N) - (R_N) + (P_N)} \\
 q^* &= \frac{U_N}{D_N + R_N} \tag{3.29}
 \end{aligned}$$

Setelah melakukan substitusi pada persamaan Tsebelis (1989), didapatkan nilai probabilitas strategi untuk tiap *player*. Probabilitas strategi untuk nasabah didapatkan [ $p^* = (C_B - P_B) / U_B$ ]. Hal ini berarti tendensi nasabah untuk melakukan pembayaran macet berbanding lurus dengan biaya yang dikeluarkan pihak bank untuk melakukan sanksi. Apabila biaya melakukan sanksi semakin besar, maka bank akan cenderung menurunkan frekuensi dilakukannya sanksi, yang akan mendorong nasabah untuk melakukan pembayaran macet karena dirasa tidak ada kerugian apabila melakukan pembayaran macet. Hal ini diperburuk dengan salah satu elemen biaya penegakan sanksi yang termasuk variabel tidak terkontrol, biaya hukum. Adanya elemen biaya yang bersifat tidak terkontrol ini makin mempersulit pihak bank untuk mengalokasikan penegakan sanksi. Akan tetapi pada persamaan  $p^*$  terdapat variabel yang dapat mengurangi besar nilai dari biaya penegakan sanksi yang dilakukan. Variabel tersebut adalah biaya yang dikeluarkan bank untuk penghargaan ( $P_B$ ). Alternatif ini dapat dilakukan

untuk mengurangi tendensi nasabah untuk melakukan pembayaran macet, dikarenakan dengan adanya iming-iming hadiah tertentu selama nasabah rajin untuk melakukan pembayaran angsuran, maka kuantitas pembayaran macet dapat ditekan. Dari persamaan  $p^*$  didapatkan juga tendensi nasabah untuk melakukan pembayaran macet berbanding terbalik dengan manfaat yang diperoleh bank dari dilakukannya sanksi. Interpretasi yang dapat dilakukan adalah, apabila pihak bank menyadari manfaat yang diperoleh dari melakukan sanksi besar, maka bank akan cenderung meningkatkan frekuensi sanksi yang juga akan berakibat pada penurunan jumlah nasabah yang melakukan pembayaran macet karena dirasakan ada kerugian yang dialami dari sanksi apabila melakukan macet.

Probabilitas strategi untuk bank didapatkan [ $q^* = U_N / (D_N + R_N)$ ]. Persamaan tersebut menunjukkan bahwa probabilitas bank melakukan sanksi memiliki perbandingan lurus dengan utilitas yang diperoleh nasabah saat melakukan pembayaran macet. Apabila dirasakan keuntungan yang diperoleh nasabah besar maka kerugian yang ditanggung bank juga besar, sehingga bank akan meningkatkan frekuensi penegakkan sanksi. Persamaan  $q^*$  juga menunjukkan probabilitas bank melakukan sanksi berbanding terbalik dengan kerugian yang dialami oleh nasabah. Implikasi ini terjadi dikarenakan nasabah merasa kerugian yang diderita besar maka kecenderungan untuk melakukan pembayaran macet akan berkurang dan bank tidak perlu melakukan sanksi terlalu sering.

- Perhitungan Distribusi Probabilitas Strategi

Pada tahap ini, setelah didapatkan formulasi  $p^*$  dan  $q^*$ , dilakukan perhitungan nilai probabilitas nasabah melakukan pembayaran macet dengan formulasi (3.28) dan (3.29). Berikut ini merupakan contoh perhitungan probabilitas nasabah melakukan pembayaran macet yang memiliki atribut besar pinjaman Rp. 108.400.000, lama tenor 216 bulan, pendapatan sebesar Rp. 1.940.741, kode pekerjaan 1, besar pinjaman pokok Rp. 485.186, besar bunga pinjaman Rp. 67.050, pembayaran lancar hingga bulan ke 194, dan mengalami keterlambatan selama 468 hari:

- Perhitungan Biaya Melakukan Sanksi

Bank X telah menentukan biaya yang dibutuhkan untuk melakukan sanksi pada seorang nasabah yang melakukan pembayaran macet sebesar Rp. 200.000.000,00 (dua ratus juta rupiah). Sehingga didapatkan nilai  $C_B$ :

$$C_B = 200.000.000$$

- Perhitungan Biaya Penghargaan Nasabah

Nilai utilitas penghargaan yang diberikan pada nasabah didapat dari nilai *cashback* dan atau nilai undian berhadiah yang didapatkan, sehingga nilai  $P_B$  adalah:

$$L = 25.000.000$$

$$C = 0,1 \times H$$

$$C = 0,1 \times 108.400.000$$

$$C = 10.840.000$$

$$P_B = L + C$$

$$P_B = 25.000.000 + 10.840.000$$

$$P_B = 35.840.000$$

- Perhitungan Utilitas Bank

Nilai utilitas bank dipengaruhi oleh nilai denda yang dikumpulkan dari nasabah ( $D'$ ), nilai *rescheduling* ( $N'$ ), dan nilai agunan hasil sitaan ( $M'$ ). Sehingga didapatkan nilai  $U_B$  adalah:

$$D' = D = \left( \sum_{t=1}^n d_t \right) \times A$$

$$D' = D = \left( \sum_{t=1}^{468} 0.1 \right) \times 552.236$$

$$D' = D = 1.292.196,89$$

$$N' = N = \frac{(H - PPxt)}{t_n} x(1 + i_n)^{t_n}$$

$$N' = N = \frac{(108.400.000 - 485.186x194)}{50} x(1 + 10)^{50}$$

$$N' = N = 25.060.773,19$$

$$M = J + \sum_{t=1}^n A_t$$

$$M = 116.490.000 + \sum_{t=1}^{194} 552.336$$

$$M = 223643184$$

$$U_B = \alpha D' + \beta N' + \delta M'$$

$$U_B = 1.292.196,89 + 25.060.773 + 223643184$$

$$U_B = 260.775.380$$

○ Perhitungan  $p^*$

$$p^* = \frac{C_B - P_B}{U_B}$$

$$p^* = \frac{200.000.000 - 35.840.000}{260.775.380}$$

$$p^* = 0,67747$$

Dengan perhitungan yang sama, dilakukan perhitungan  $p^*$  untuk tiap-tiap nasabah yang melakukan kredit macet dengan atributnya masing-masing. Hasil perhitungan  $p^*$  untuk tiap nasabah macet ditampilkan pada lampiran B.

### **3.4 Tahap Hasil dan Analisis Model**

Tahap ini akan dilakukan analisis untuk dua model yang telah dibuat. Analisis pertama adalah mengenai bagaimana kecepatan komputasi model dari *decision tree* terhadap data *testing* yang diuji untuk menghasilkan suatu respon keputusan dari variabel *predictor* terkait, serta keakuratan model *decision tree* untuk memberi label pada data *testing* tertentu. Analisis kedua adalah mengenai variabel-variabel apa saja yang dapat mempengaruhi titik kesetimbangan dalam model *game* seperti fleksibilitas penentuan nominal pinjaman, sanksi yang diberikan, serta variabel lainnya, yang nantinya dijadikan strategi khusus untuk meminimasi risiko kredit macet.

### **3.5 Tahap Kesimpulan dan Saran**

Pada tahapan ini dilakukan penarikan kesimpulan dari hasil analisis dan rekomendasi perbaikan sesuai dengan tujuan yang ingin peneliti capai dalam melakukan penelitian. Kemudian peneliti membuat saran kepada penelitian selanjutnya.

## BAB 4

### HASIL DAN ANALISIS

#### 4.1 Hasil Model

Pada subbab ini akan ditampilkan hasil dari penyusunan model *decision tree* dan model *inspection game* beserta *output* dari tiap-tiap model.

##### 4.1.1 Hasil Decision Tree

Setelah serangkaian proses penyusunan model *decision tree*, didapatkan *decision tree* optimal dengan komposisi data *training* dan data *testing* sebesar 95% data *training* dan 5% data *testing*. Proses selanjutnya adalah proses *prunning* untuk mensimplifikasi bentuk *decision tree* serta meningkatkan akurasi prediksi terhadap data *testing*. Proses *prunning* mengikuti aturan *resubstitution estimate*, dimana beberapa level *prunning* dihitung nilai *resubstitution estimate* yang paling kecil. Nilai *resubstitution estimate* untuk tiap level *prunning* ditampilkan pada Tabel 4.1.

Tabel 4.1 Hasil *Prunning Decision Tree*

Level Prunning	Resubstitution Cost	Complexity	POD	TNR	OA
0	0,716	0,00000	97,56%	100,00%	97,82%
1	0,638	0,00025	99,39%	92,00%	98,35%
2	0,450	0,00138	99,50%	100,00%	99,80%
3	0,508	0,00200	100,00%	88,88%	98,21%
4	0,576	0,00800	98,06%	94,87%	97,52%
5	0,645	0,00950	97,78%	97,56%	97,75%
6	1,000	0,02000	85,87%	88,80%	87,67%

Hasil dari *prunning* menghasilkan *decision tree* dengan tujuh simpul terminal dan delapan simpul daun. Variabel yang masuk menjadi variabel *predictor* adalah besar pinjaman (x1), tenor (x2), pendapatan (x4), dan proporsi pembiayaan (x5). Penjelasan kondisi masing-masing simpul adalah sebagai berikut:

- Kondisi Simpul Terminal

- Simpul Terminal 1

Terdapat 866 pengamatan, aturan yang berlaku adalah tenor dengan *threshold* 282. Amatan yang memiliki nilai tenor di atas 282 akan diprediksi

menjadi macet. Amatan yang memiliki nilai tenor kurang dari atau sama dengan 282 akan dilakukan proses pemilahan kembali.

- Simpul Terminal 2

Terdapat 785 pengamatan, aturan yang berlaku adalah besar proporsi pembiayaan dengan *threshold* 0,496103. Pada simpul ini hasil pemilahan masih dilakukan proses pemilahan kembali pada simpul terminal 3 dan simpul terminal 4.

- Simpul Terminal 3

Terdapat 46 pengamatan, aturan yang berlaku adalah pendapatan dengan *threshold* 16.955.600. Amatan yang memiliki nilai pendapatan di atas *threshold* akan diprediksi lancar. Amatan yang memiliki nilai pendapatan di bawah *threshold* akan diprediksi macet.

- Simpul Terminal 4

Terdapat 739 pengamatan, aturan yang berlaku adalah besar pinjaman dengan *threshold* 87.500.000. Amatan yang memiliki nilai besar pinjaman di atas *threshold* akan dilakukan proses pemilahan kembali pada simpul terminal 5. Amatan yang memiliki nilai besar pinjaman di bawah *threshold* akan diprediksi lancar.

- Simpul Terminal 5

Terdapat 730 pengamatan, aturan yang berlaku adalah besar proporsi pembiayaan dengan *threshold* 0,654743. Amatan yang memiliki nilai besar proporsi di atas *threshold* akan diprediksi lancar. Amatan yang memiliki nilai besar proporsi pembiayaan di bawah *threshold* akan dilanjutkan proses pemilahan pada simpul terminal 6.

- Simpul Terminal 6

Terdapat 100 pengamatan, aturan yang berlaku adalah pendapatan dengan *threshold* 3.900.000. Amatan yang memiliki nilai pendapatan di atas *threshold* akan diprediksi lancar. Amatan yang memiliki nilai pendapatan di bawah *threshold* akan dilanjutkan proses pemilahan pada simpul terminal 7.

- Simpul Terminal 7

Terdapat 23 pengamatan, aturan yang berlaku adalah besar pinjaman dengan *threshold* 174.600.000. Amatan yang memiliki nilai besar pinjaman

di atas *threshold* akan diprediksi macet. Amatan yang memiliki nilai besar pinjaman di bawah *threshold* akan diprediksi lancar.

- Kondisi Simpul Daun

- Simpul Daun 1

Terdapat 81 pengamatan, dengan 2 pengamatan lancar dan 79 pengamatan macet. Variabel yang terdapat pada simpul ini adalah tenor di bawah 282. Prediksi kelas untuk simpul ini adalah macet. *Level of confidence* untuk prediksi label kelas ini adalah sebesar 97,5%.

- Simpul Daun 2

Terdapat 43 pengamatan, dengan 3 pengamatan lancar dan 40 pengamatan macet. Variabel yang terdapat pada simpul ini adalah tenor di bawah 282, pendapatan di bawah 16.955.600, dan proporsi pembiayaan di bawah 0,496103. Prediksi kelas untuk simpul ini adalah macet. *Level of confidence* untuk prediksi label kelas ini adalah sebesar 93%.

- Simpul Daun 3

Terdapat 3 pengamatan, dengan 2 pengamatan lancar dan 1 pengamatan macet. Variabel yang terdapat pada simpul ini adalah tenor di bawah 282, pendapatan di atas 16.955.600, dan proporsi pembiayaan di bawah 0,496103. Prediksi kelas untuk simpul ini adalah lancar. *Level of confidence* untuk prediksi label kelas ini adalah sebesar 66,67%.

- Simpul Daun 4

Terdapat 9 pengamatan, dengan 5 pengamatan lancar dan 4 pengamatan macet. Variabel yang terdapat pada simpul ini adalah tenor di bawah 282, besar pinjaman di bawah 87.500.000, dan proporsi pembiayaan di bawah 0,496103. Prediksi kelas untuk simpul ini adalah lancar. *Level of confidence* untuk prediksi label kelas ini adalah sebesar 55,56%.

- Simpul Daun 5

Terdapat 630 pengamatan, dengan 624 pengamatan lancar dan 6 pengamatan macet. Variabel yang terdapat pada simpul ini adalah tenor di bawah 282, besar pinjaman di bawah 87.500.000, dan proporsi pembiayaan di bawah 0,654743. Prediksi kelas untuk simpul ini adalah lancar. *Level of confidence* untuk prediksi label kelas ini adalah sebesar 99,05%.

- Simpul Daun 6

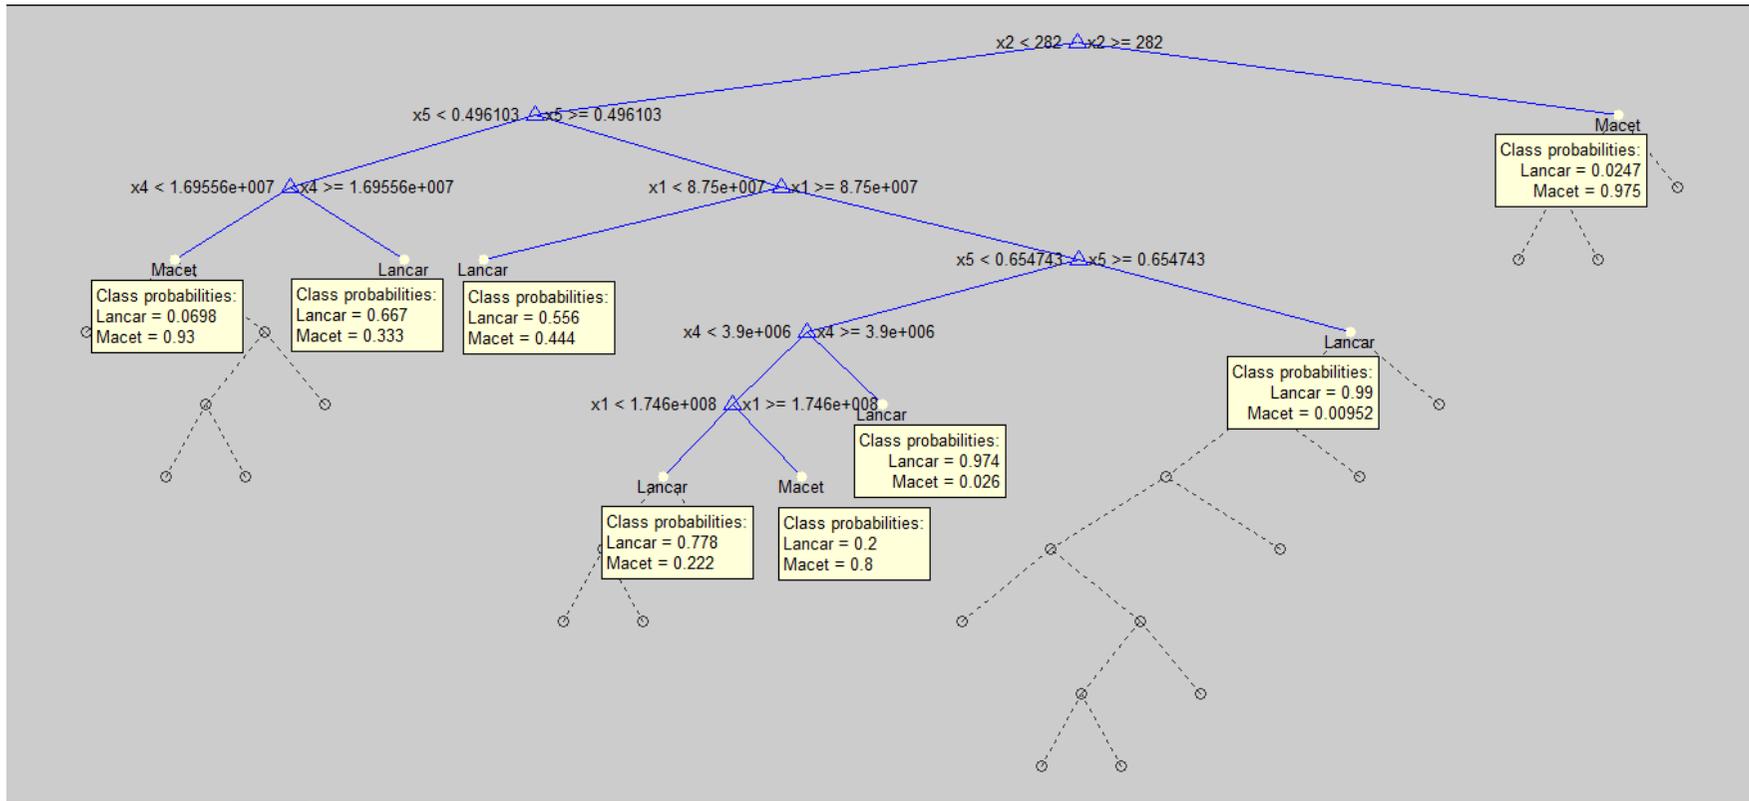
Terdapat 77 pengamatan, dengan 75 pengamatan lancar dan 2 pengamatan macet. Variabel yang terdapat pada simpul ini adalah tenor di bawah 282, besar pinjaman di bawah 87.500.000, pendapatan di bawah 3.900.000, dan besar proporsi pembiayaan berada pada rentang 0,496103-0,654743. Prediksi kelas untuk simpul ini adalah lancar. *Level of confidence* untuk prediksi label kelas ini adalah sebesar 97,4%.

- Simpul Daun 7

Terdapat 18 pengamatan, dengan 14 pengamatan lancar dan 4 pengamatan macet. Variabel yang terdapat pada simpul ini adalah tenor di bawah 282, besar pinjaman berada pada rentang 87.500.000 - 174.600.000, pendapatan di bawah 3.900.000, dan besar proporsi pembiayaan berada pada rentang 0,496103-0,654743. Prediksi kelas untuk simpul ini adalah lancar. *Level of confidence* untuk prediksi label kelas ini adalah sebesar 77,8%.

- Simpul Daun 8

Terdapat 5 pengamatan, dengan 1 pengamatan lancar dan 4 pengamatan macet. Variabel yang terdapat pada simpul ini adalah tenor di bawah 282, besar pinjaman di bawah 174.600.000, pendapatan di bawah 3.900.000, dan besar proporsi pembiayaan berada pada rentang 0,496103-0,654743. Prediksi kelas untuk simpul ini adalah macet. *Level of confidence* untuk prediksi label kelas ini adalah sebesar 80%.



Gambar 4.1 *Decision Tree* Optimal

Gambar 4.1 diatas merupakan bentuk optimal dari *decision tree* yang telah dilakukan proses *prunning*. Model ini memiliki empat variabel *predictor*, tujuh simpul terminal, dan delapan simpul daun.

#### 4.1.2 Metode Pengambilan Keputusan

Model *decision tree* yang telah dibentuk, telah memberikan gambaran umum mengenai bagaimana seorang pemohon peminjam kredit dapat diketahui akan berpotensi melakukan pembayaran kredit secara lancar atau macet. Tata cara mengenai pengambilan keputusan yang dapat diambil dari model *decision tree* yang dibentuk dijelaskan dengan tahapan berikut ini:

1. Evaluasi mengenai lama tenor yang diajukan oleh nasabah, apabila lama tenor lebih besar atau sama dengan 282 bulan maka nasabah berpotensi macet, apabila kurang dari maka lanjut poin nomer dua.
2. Evaluasi mengenai besar proporsi pembiayaan yang diajukan oleh nasabah, apabila kurang dari 0,496103 lanjut poin nomer tiga, apabila lebih besar atau sama dengan 0,496103 maka lanjut poin nomer empat.
3. Evaluasi mengenai besar pendapatan nasabah, apabila kurang dari Rp. 16.955.600 maka nasabah berpotensi macet, apabila lebih besar atau sama dengan Rp. 16.955.600 maka nasabah berpotensi lancar.
4. Evaluasi mengenai besar pinjaman yang diajukan oleh nasabah, apabila kurang dari Rp. 87.500.000 maka nasabah berpotensi lancar, apabila lebih besar atau sama dengan Rp. 87.500.000 maka lanjut poin nomer lima.
5. Evaluasi kembali mengenai besar proporsi pembiayaan yang diajukan oleh nasabah, apabila kurang dari 0,654743 maka lanjut poin enam, apabila lebih besar atau sama dengan 0,654743 maka nasabah berpotensi lancar.
6. Evaluasi kembali mengenai besar pendapatan nasabah, apabila kurang dari Rp. 3.900.000 maka lanjut poin nomer tujuh, apabila lebih besar atau sama dengan Rp.3.900.000 maka nasabah berpotensi lancar.
7. Evaluasi kembali mengenai besar pinjaman yang diajukan oleh nasabah, apabila kurang dari Rp. 174.600.000 maka nasabah berpotensi lancar, apabila lebih besar atau sama dengan Rp. 174.600.000 maka nasabah berpotensi macet.

#### 4.1.3 Hasil Inspection Game

Setelah didapatkan nilai  $p^*$  dan  $q^*$  dari tiap-tiap tipe nasabah, maka bank dapat menguji pengaruh kebijakan yang dapat meminimasi kuantitas nasabah yang

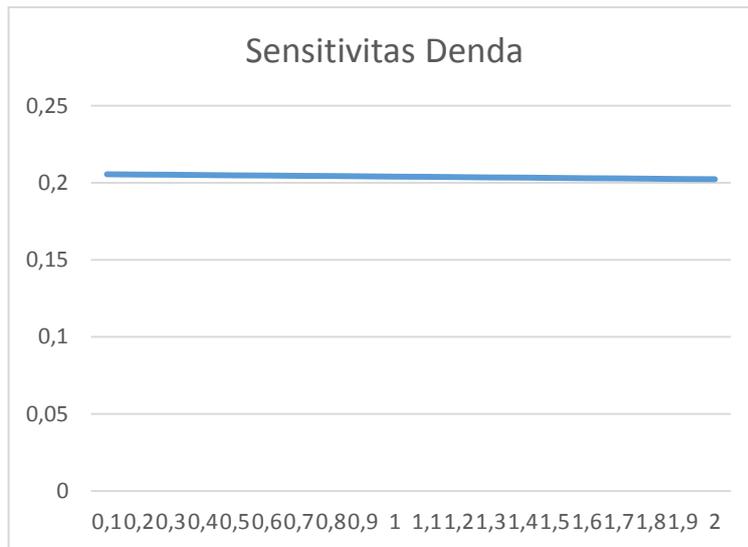
akan melakukan kredit macet. Metode pengujian yang dapat dilakukan adalah mengubah nilai parameter variabel kontrol yang ada. Perubahan nilai dapat dilakukan dengan menaikkan atau menurunkan nilai parameter sejauh batasan atau ketentuan yang berlaku. Variabel-variabel kontrol yang akan dilakukan uji sensitivitas adalah presentase denda, tingkat suku bunga yang diterapkan saat melakukan *rescheduling*, lama tenor saat melakukan *rescheduling*, dan presentase *cashback* yang dilakukan.

Besar perubahan yang dapat dilakukan untuk presentase denda sesuai dengan aturan yang dibuat oleh Otoritas Jasa Keuangan (OJK), yakni OJK telah mengeluarkan POJK Nomor 3/POJK.02/2014 Tahun 2014. Menurut peraturan, besar denda yang boleh dibebankan pada nasabah berada pada rentang 0,0001/hari keterlambatan sampai dengan 0,001/hari keterlambatan.

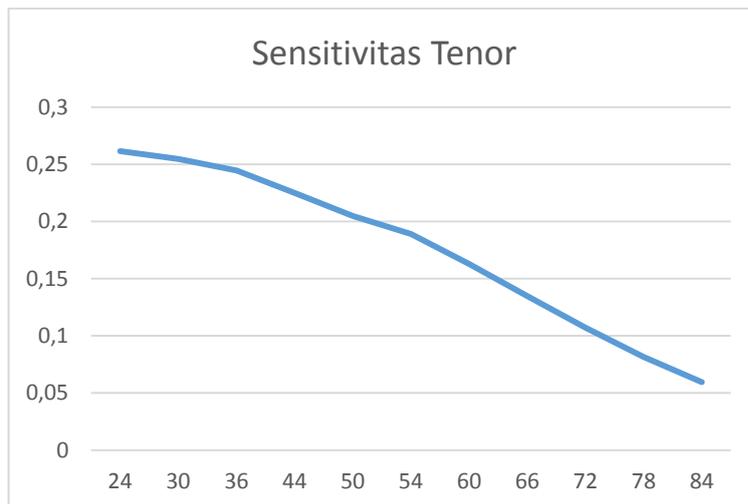
Besar perubahan yang dapat dilakukan untuk suku bunga mengikuti peraturan Bank Indonesia Nomor 17/10/PBI/2015. Menurut peraturan, rasio *Loan to Value* yang boleh diberikan bank adalah sebesar 9%-20%. Sedang untuk lama waktu tenor baru, bank X memiliki ketentuan lama tenor paling cepat adalah 24 bulan dan paling lama 84 bulan.

Kebijakan *cashback* yang ditentukan oleh Bank X telah mengalokasikan dana untuk *cashback* yakni sebesar 6%-15% dari pinjaman yang diberikan, apabila nasabah membayar angsuran tepat waktu pada saat pelunasan terakhir.

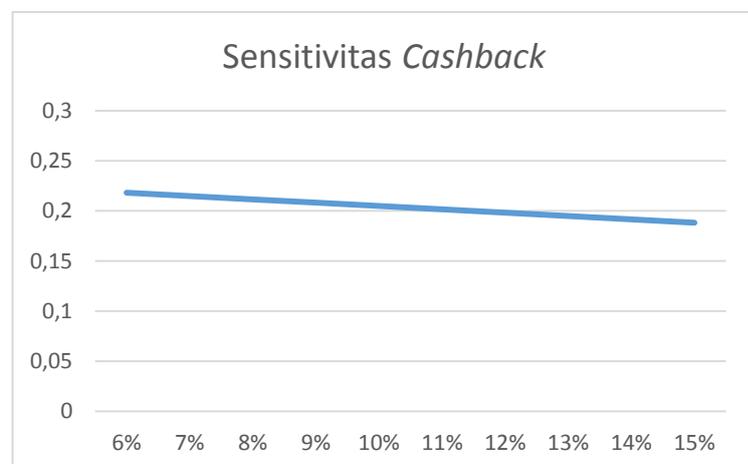
Proses uji sensitivitas yang telah dilakukan ditampilkan pada lampiran B. Sedangkan hasil uji sensitivitas ditampilkan pada Gambar 4.2 hingga Gambar 4.5.



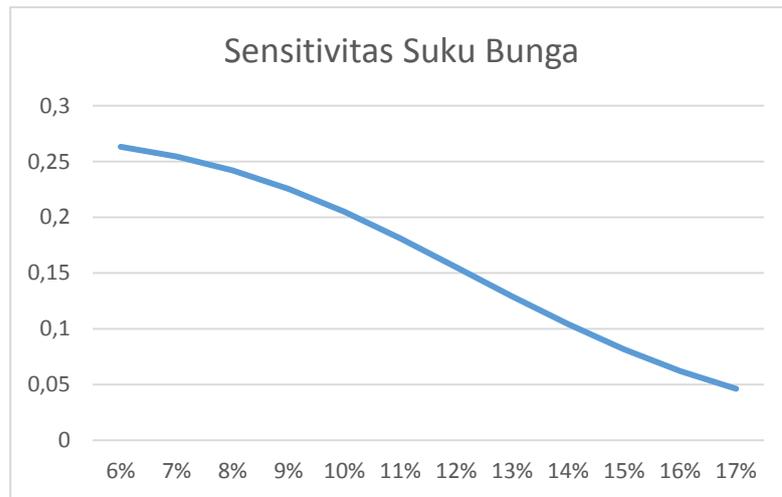
Gambar 4.2 Sensitivitas Denda



Gambar 4.3 Sensitivitas Tenor



Gambar 4.4 Sensitivitas *Cashback*



Gambar 4.5 Sensitivitas Suku Bunga

## 4.2 Analisis Model

Pada subbab ini akan ditampilkan analisis model *decision tree* dan analisis model *inspection game*.

### 4.2.1 Analisis Decision Tree

Model *decision tree* optimal yang didapatkan memiliki nilai *Probability of Detection* (POD) 99,50%, *True Negative Rate* (TNR) 100%, dan *Overall Accuracy* (OA) 99,80%. Tingkat keakuratan hasil prediksi model *decision tree* yang dibentuk telah berhasil memenuhi kriteria keputusan awal mengenai kebijakan pengambilan keputusan persetujuan proposal kredit dari Bank X, yakni 95%. Kriteria keputusan kedua mengenai tingkat risiko proposal macet dapat dilihat dari *level of confidence* sebuah simpul daun. *Level of confidence* dari sebuah simpul daun dapat merepresentasikan tingkat keyakinan prediksi terhadap proposal yang masuk mengenai peluang terjadinya kredit macet. Dalam kasus ini berarti semakin tinggi nilai *level of confidence*, maka semakin tinggi tingkat kebenaran prediksi. Kelas-kelas atau kelompok-kelompok yang memiliki risiko kredit yang rendah adalah: simpul daun 5 dengan risiko terjadinya kredit macet sebesar 0,952% dan simpul daun 6 dengan risiko terjadinya kredit macet sebesar 2,6%. Kriteria keputusan selanjutnya adalah mengenai proposal yang memiliki keuntungan yang besar. Kriteria ini dapat direpresentasikan dari besar pinjaman serta pendapatan yang

dimiliki oleh nasabah. Kelompok yang memiliki kriteria tersebut adalah simpul daun 3 dengan besar pendapatan di atas 16.995.600 dan jumlah pinjaman di atas 174.600.000, akan tetapi kelompok ini memiliki tingkat risiko terjadinya kredit macet yang cukup tinggi yakni 33,33%. Kriteria terakhir mengenai lama waktu pengembalian pinjaman. Hal ini dapat dilihat dari lama tenor tiap kelompok. Terdapat tujuh kelompok yang memiliki atribut lama tenor yang sama, yakni di bawah 282 bulan. Kelompok tersebut adalah simpul daun 2, simpul daun 3, simpul daun 4, simpul daun 5, simpul daun 6, simpul daun 7, dan simpul daun 8.

Model *decision tree* yang telah dibentuk berhasil memenuhi beberapa kriteria keputusan yang diajukan oleh pihak bank. Sehingga dengan pencapaian ini, model *decision tree* yang telah dibentuk dapat dinilai layak dan dapat diaplikasikan untuk menjawab persoalan prediksi kredit macet.

#### 4.2.2 Analisis Model Inspection Game

Model *inspection game* yang telah terbentuk didapatkan [ $p^*=(C_B-P_B)/U_B$ ]. Ini berarti probabilitas nasabah melakukan kredit macet akan berbanding lurus dengan biaya yang dikeluarkan bank untuk melakukan sanksi, dan berbanding terbalik dengan manfaat yang diperoleh bank dari melakukan sanksi. Dari model *inspection game* juga didapatkan [ $q^*=U_N/(D_N+R_N)$ ]. Hal ini berarti probabilitas bank melakukan sanksi sebanding dengan perolehan nasabah ketika melakukan pembayaran macet, dan berbanding terbalik dengan disutilitas nasabah ketika melakukan pembayaran macet.

Pola sanksi yang diterapkan saat ini mengakibatkan nasabah merasa kerugian yang dialami dari penegakkan sanksi tidaklah besar. Disisi lain, nasabah merasa keuntungan yang diperoleh dari kredit macet besar, sehingga kondisi sekarang memicu nasabah untuk semakin melakukan kredit macet. Bertambahnya jumlah nasabah yang melakukan kredit macet memicu bank untuk meningkatkan frekuensi penegakkan sanksi. Dari kondisi tersebut, keadaan yang terjadi dengan kebijakan yang diterapkan sekarang adalah pihak bank sering melakukan penegakkan sanksi tetapi tidak dapat menurunkan jumlah nasabah yang melakukan kredit macet.

Hasil uji sensitivitas dapat menunjukkan variabel keputusan mana dari alternatif kebijakan yang dapat memberikan manfaat berupa penurunan jumlah nasabah secara signifikan. Empat variabel keputusan yang diuji didapatkan dua variabel yang dapat memberikan penurunan jumlah nasabah melakukan kredit macet. Variabel keputusan tersebut adalah tingkat suku bunga baru dan lama waktu tenor baru. Hasil grafik menunjukkan peningkatan jumlah suku bunga dan tenor mengakibatkan penurunan jumlah kredit macet yang terjadi. Hal ini dikarenakan dengan bertambahnya tingkat suku bunga dan tenor, nasabah merasakan kerugian akibat melakukan kredit macet semakin besar. Berdasarkan hubungan sebab-akibat tersebut maka nilai dari tingkat suku bunga yang memberikan jumlah nasabah melakukan kredit macet paling kecil adalah 17%, sedangkan untuk tenor adalah 84 bulan.

#### 4.2.3 Analisis Model Keseluruhan

Model *decision tree* yang terbentuk telah dapat memberikan visualisasi mengenai kondisi nasabah yang berpotensi lancar maupun berpotensi macet. Visualisasi yang dihasilkan berhasil memenuhi tiga kriteria keputusan yang telah ditetapkan oleh pihak Bank. *Decision tree* dapat menginformasikan kelompok nasabah mana yang memiliki risiko macet yang paling kecil, juga kelompok nasabah mana yang berpotensi memberikan keuntungan paling besar, serta kelompok nasabah mana yang memberikan pengembalian paling cepat. Namun dibalik itu semua, ditemukan suatu kekurangan model *decision tree* yakni model tidak dapat memberikan nilai *trade off* dari kriteria keputusan yang ditetapkan. *Decision tree* tidak dapat memberikan suatu informasi mengenai seberapa besar keuntungan atau kerugian yang akan dialami jika memilih kelompok nasabah yang memiliki potensi keuntungan yang besar tapi memiliki risiko kredit macet yang tinggi. Begitu juga *trade off* lain yang dapat dilakukan, sehingga diperlukan suatu pendekatan lebih dalam untuk memperbaiki model *decision tree*. Langkah yang mungkin dapat ditempuh adalah menambah variabel-variabel yang dapat mengakomodasi nilai *trade off* yang ada. Sehingga hasil prediksi yang didapat juga mampu menggambarkan *trade off* yang dilakukan.

Model *inspection game* memiliki asumsi dasar mengenai setiap *player* merupakan individu yang rasional dan melakukan pengambilan keputusan sesuai nalar. Fakta dilapangan menunjukkan hal yang bertolakbelakang dengan asumsi yang ditetapkan. Keputusan-keputusan yang diambil oleh satu atau semua *player* tak jarang berada diluar nalar pemikiran orang normal, banyak faktor yang memengaruhi pengambilan keputusan yang diluar nalar tadi. Hal ini tentunya membuat model menjadi tidak relevan lagi untuk diterapkan, sehingga perlu dilakukan penyesuaian-penyesuaian tertentu agar model tetap relevan untuk diimplementasikan. Penyesuaian pertama yang telah dilakukan adalah menyertakan variabel yang merupakan nilai dari dampak psikologis yang dialami *player*. Variabel ini merupakan sebuah pendekatan untuk membuat model menjadi lebih fleksibel dalam mengakomodasi permasalahan riil.

## **BAB 5**

### **KESIMPULAN DAN SARAN**

Bab ini menjelaskan kesimpulan dari hasil pelaksanaan penelitian tugas akhir sesuai dengan tujuan yang ingin dicapai serta saran-saran yang dapat diberikan untuk perbaikan penelitian selanjutnya.

#### **5.1 Kesimpulan**

Berdasarkan penelitian yang telah dilakukan, berikut ini adalah kesimpulan yang dapat diambil:

1. Model *decision tree* yang telah disusun berhasil memenuhi kriteria keputusan tingkat akurasi 95% yang telah ditetapkan Bank X. Pencapaian tingkat akurasi dari model *decision tree* telah disusun adalah: *Probability of Detection* (POD) sebesar 99,50%, *True Negative Rate* (TNR) sebesar 100%, dan *Overall Accuracy* (OA) sebesar 99,80%.
2. Model *inspection game* yang telah disusun berhasil memberikan gambaran mengenai kebijakan yang harus diterapkan Bank X agar dapat meminimasi jumlah nasabah yang melakukan kredit macet. Kebijakan yang seharusnya diterapkan adalah mengubah tingkat suku bunga dan tenor pada kebijakan *rescheduling*. Tingkat suku bunga 17% dapat menekan proporsi nasabah yang melakukan kredit macet menjadi 4,6%. Lama tenor 84 bulan dapat menekan proporsi nasabah melakukan kredit macet menjadi 5,9%.
3. Berdasarkan kriteria keputusan yang telah ditetapkan oleh Bank X, model *decision tree* dan *inspection game* dinilai dapat diaplikasikan pada kasus nyata dikarenakan berhasil memenuhi kriteria-kriteria yang telah ditentukan.

#### **5.2 Saran**

Berikut ini adalah saran yang dapat diberikan untuk perbaikan pada penelitian selanjutnya.

1. Penelitian selanjutnya dapat melibatkan atribut lain sebagai variabel *predictor* dalam penyusunan model *decision tree*, seperti nilai kekayaan yang dimiliki nasabah dan hutang lain yang dimiliki, sehingga dapat lebih

menggambarkan kondisi nasabah dan berpeluang mendapat hasil prediksi yang lebih baik.

2. Dalam penyusunan model *inspection game*, penelitian selanjutnya dapat melakukan identifikasi variabel lebih lanjut serta mempertimbangkan alternatif kebijakan lain diluar kebijakan yang telah diterapkan agar berpotensi mendapat hasil yang lebih baik.

## DAFTAR PUSTAKA

- Daellenbach, H. G. & McNickle, D. C., 2005. *Management Science Decision Making Through Systems Thinking*. New York: PALGRAVE MCMILLAN.
- Gorunescu, F., 2011. *Data Mining Concept, Model Technique*. Rumania: Springer.
- Handoyo, F. W. & Kautsar, I., 2014. Strategi Pemberantasan Korupsi di Indonesia Menggunakan Inspection Game. *Ekonomi dan Pembangunan*, Volume 22, pp. 27-38.
- Han, J. & Kamber, M., 2006. *Data Mining Concepts and Techniques*. San Fransisco: Elsevier.
- Indonesia, B., 2015. *Peraturan Bank Indonesi Nomor 17/10/PBI/2015*. Jakarta: Bank Indonesia.
- Indonesia, P., 1998. *Undang-Undang Republik Indonesia Nomor 10 Tahun 1998*. Jakarta: Pemerintah Indonesia.
- Joko, D. & Yahya, K., 2013. Analisa Risiko Kredit Sepeda Motor Pada PT. X Finance. *Jurnal Sains dan Seni POMITS*, Volume 2, pp. 231-236.
- Kasmir, 2012. *Manajemen Perbankan*. Jakarta: RajaGrafindo Persada.
- Maschler, M., Solan, E. & Zamir, S., 2013. *Game Theory*. Cambridge: Cambridge University Press.
- Matsumoto, A. & Szidarovszky, F., 2016. *Game Theory and Its Applications*. s.l.:Springer.
- Quinlan, J. R., 1985. Induction of Decision Tree. *Machine Learning 1*, pp. 81-106.
- Sadler, A. & Eugene, H., 2010. Intuitive Decision Making in Banking and Finance.
- Santosa, B., 2007. *Data Mining Teknik Pemanfaatan Data untuk Keperluan Bisnis*. Jakarta: Graha Ilmu.
- Tsebelis, G., 1989. The Abuse of Probability in Political Analysis: The Robinson Crusoe Fallacy. *The American Political Science Review*, Volume 83, pp. 77-91.
- Winston, W. L., 2003. *Operation Research Applications and Algorithms*. 4th ed. s.l.:Duxbury Press.
- Zhang, J. L. & Hardle, W. K., 2008. The Bayesian Additive Classification Tree Applied to Credit Risk Modelling. *SFB 649 Economic Risk Berlin*.

*Halaman ini sengaja dikosongkan*

## LAMPIRAN A

### KODE MATLAB

```
>> load predictorTA
>> load labelTA
o Penyusunan Model Decision Tree (75%-25%)
>> training=data(1:685,:);
>> testing=data(686:912,:);
>> labelt=label(1:685,:);
>> labele=label(686:912,:);
>> tree75=classregtree(training,labelt,'names',{'x1' 'x2' 'x3' 'x4'
'x5' 'x6'})
o Penyusunan Model Decision Tree (80%-20%)
>> training=data(1:730,:);
>> testing=data(731:912,:);
>> labelt=label(1:730,:);
>> labele=label(731:912,:);
>> tree80=classregtree(training,labelt,'names',{'x1' 'x2' 'x3' 'x4'
'x5' 'x6'})
o Penyusunan Model Decision Tree (85%-15%)
>> training=data(1:800,:);
>> testing=data(801:912,:);
>> labelt=label(1:800,:);
>> labele=label(801:912,:);
>> tree85=classregtree(training,labelt,'names',{'x1' 'x2' 'x3' 'x4'
'x5' 'x6'})
o Penyusunan Model Decision Tree (90%-10%)
>> training=data(1:820,:);
>> testing=data(821:912,:);
>> labelt=label(1:820,:);
>> labele=label(821:912,:);
>> tree90= classregtree(training,labelt,'names',{'x1' 'x2' 'x3'
'x4' 'x5' 'x6'})
```

**LAMPIRAN B**  
**DATA PEMOHON KPR**

Besar Pinjaman	Tenor	Nilai Agunan	Pendapatan	Proporsi Pembiayaan	Sektor Pekerjaan	Status
Rp 70.000.000	36	Rp 666.672.000	Rp 7.777.778	0,1050	7	Macet
Rp 110.600.000	180	Rp 629.460.000	Rp 2.457.778	0,1757	2	Macet
Rp 131.400.000	120	Rp 665.890.000	Rp 4.380.000	0,1973	4	Lancar
Rp 500.000.000	60	Rp2.369.500.000	Rp 33.333.333	0,2110	10	Lancar
Rp 254.000.000	72	Rp1.182.900.000	Rp 14.111.111	0,2147	10	Macet
Rp 203.280.000	180	Rp 907.500.000	Rp 4.517.333	0,2240	4	Macet
Rp 240.000.000	120	Rp1.026.090.000	Rp 8.000.000	0,2339	7	Macet
Rp 100.000.000	120	Rp 420.000.000	Rp 3.333.333	0,2381	3	Macet
Rp 85.000.000	60	Rp 318.600.000	Rp 5.666.667	0,2668	5	Macet
Rp 150.000.000	168	Rp 555.100.000	Rp 3.571.429	0,2702	3	Macet
Rp 100.000.000	108	Rp 362.000.000	Rp 3.703.704	0,2762	3	Lancar
Rp 341.600.000	60	Rp1.130.960.000	Rp 22.773.333	0,3020	10	Macet
Rp 340.000.000	120	Rp1.084.050.000	Rp 11.333.333	0,3136	10	Macet
Rp 190.300.000	120	Rp 594.560.000	Rp 6.343.333	0,3201	6	Macet
Rp 229.500.000	240	Rp 710.400.000	Rp 3.825.000	0,3231	3	Macet
Rp 100.000.000	120	Rp 303.410.000	Rp 3.333.333	0,3296	3	Macet
Rp 297.000.000	60	Rp 897.200.000	Rp 19.800.000	0,3310	10	Lancar
Rp 260.000.000	96	Rp 782.400.000	Rp 10.833.333	0,3323	10	Macet
Rp 196.300.000	72	Rp 588.700.000	Rp 10.905.556	0,3334	10	Macet
Rp 115.000.000	132	Rp 328.100.000	Rp 3.484.848	0,3505	3	Macet
Rp 120.000.000	180	Rp 334.200.000	Rp 2.666.667	0,3591	2	Macet
Rp 222.800.000	300	Rp 617.700.000	Rp 2.970.667	0,3607	2	Macet
Rp 350.000.000	108	Rp 968.500.000	Rp 12.962.963	0,3614	10	Macet
Rp 558.000.000	180	Rp1.433.750.000	Rp 12.400.000	0,3892	10	Macet
Rp 114.000.000	180	Rp 289.000.000	Rp 2.533.333	0,3945	2	Macet
Rp 91.600.000	180	Rp 227.283.000	Rp 2.035.556	0,4030	2	Macet
Rp 107.900.000	60	Rp 265.620.000	Rp 7.193.333	0,4062	7	Macet
Rp 189.200.000	180	Rp 460.500.000	Rp 4.204.444	0,4109	4	Macet
Rp 296.178.000	180	Rp 712.800.000	Rp 6.581.733	0,4155	6	Macet
Rp 150.000.000	120	Rp 358.080.000	Rp 5.000.000	0,4189	4	Macet
Rp 100.000.000	120	Rp 237.620.000	Rp 3.333.333	0,4208	3	Macet
Rp 225.000.000	300	Rp 534.550.000	Rp 3.000.000	0,4209	2	Macet
Rp 457.300.000	300	Rp1.076.000.000	Rp 6.097.333	0,4250	6	Macet
Rp 265.000.000	240	Rp 610.850.000	Rp 4.416.667	0,4338	4	Macet
Rp 104.200.000	180	Rp 237.620.000	Rp 2.315.556	0,4385	2	Lancar
Rp 375.000.000	120	Rp 841.400.000	Rp 12.500.000	0,4457	10	Macet
Rp 480.000.000	240	Rp1.076.000.000	Rp 8.000.000	0,4461	7	Macet

Besar Pinjaman	Tenor	Nilai Agunan	Pendapatan	Proporsi Pembiayaan	Sektor Pekerjaan	Status
Rp 135.000.000	60	Rp 302.501.000	Rp 9.000.000	0,4463	8	Macet
Rp 371.000.000	240	Rp 829.800.000	Rp 6.183.333	0,4471	6	Macet
Rp 200.000.000	96	Rp 444.150.000	Rp 8.333.333	0,4503	8	Macet
Rp 192.300.000	84	Rp 415.800.000	Rp 9.157.143	0,4625	9	Macet
Rp 141.700.000	180	Rp 306.010.000	Rp 3.148.889	0,4631	3	Macet
Rp 105.000.000	180	Rp 226.576.000	Rp 2.333.333	0,4634	2	Macet
Rp 53.500.000	48	Rp 114.984.000	Rp 4.458.333	0,4653	4	Macet
Rp 106.000.000	120	Rp 227.283.000	Rp 3.533.333	0,4664	3	Macet
Rp 139.700.000	120	Rp 297.744.000	Rp 4.656.667	0,4692	4	Macet
Rp 125.000.000	96	Rp 265.620.000	Rp 5.208.333	0,4706	5	Macet
Rp 125.200.000	300	Rp 265.620.000	Rp 1.669.333	0,4714	1	Macet
Rp 125.229.000	180	Rp 265.620.000	Rp 2.782.867	0,4715	2	Macet
Rp 435.500.000	96	Rp 923.700.000	Rp 18.145.833	0,4715	10	Macet
Rp 500.000.000	180	Rp1.060.340.000	Rp 11.111.111	0,4715	10	Macet
Rp 130.500.000	300	Rp 276.000.000	Rp 1.740.000	0,4728	1	Macet
Rp 125.000.000	120	Rp 264.000.000	Rp 4.166.667	0,4735	4	Macet
Rp 300.000.000	300	Rp 627.000.000	Rp 4.000.000	0,4785	3	Macet
Rp 350.000.000	300	Rp 721.500.000	Rp 4.666.667	0,4851	4	Macet
Rp 146.250.000	180	Rp 297.744.000	Rp 3.250.000	0,4912	3	Macet
Rp 156.000.000	60	Rp 316.801.000	Rp 10.400.000	0,4924	10	Macet
Rp 275.000.000	240	Rp 555.900.000	Rp 4.583.333	0,4947	4	Macet
Rp 390.000.000	120	Rp 783.900.000	Rp 13.000.000	0,4975	10	Lancar
Rp 57.500.000	60	Rp 115.200.000	Rp 3.833.333	0,4991	3	Lancar
Rp 353.000.000	300	Rp 703.630.000	Rp 4.706.667	0,5017	4	Macet
Rp 170.000.000	180	Rp 337.800.000	Rp 3.777.778	0,5033	3	Lancar
Rp 150.000.000	240	Rp 295.370.000	Rp 2.500.000	0,5078	2	Lancar
Rp 125.000.000	120	Rp 244.900.000	Rp 4.166.667	0,5104	4	Lancar
Rp 174.200.000	180	Rp 340.924.000	Rp 3.871.111	0,5110	3	Lancar
Rp 550.000.000	264	Rp1.076.000.000	Rp 8.333.333	0,5112	8	Lancar
Rp 550.000.000	180	Rp1.076.000.000	Rp 12.222.222	0,5112	10	Lancar
Rp 550.000.000	180	Rp1.076.000.000	Rp 12.222.222	0,5112	10	Lancar
Rp 554.400.000	180	Rp1.076.000.000	Rp 12.320.000	0,5152	10	Lancar
Rp 200.000.000	180	Rp 387.918.000	Rp 4.444.444	0,5156	4	Lancar
Rp 170.000.000	120	Rp 329.000.000	Rp 5.666.667	0,5167	5	Lancar
Rp 222.000.000	96	Rp 429.481.000	Rp 9.250.000	0,5169	9	Macet
Rp 275.100.000	180	Rp 530.000.000	Rp 6.113.333	0,5191	6	Lancar
Rp 558.800.000	180	Rp1.076.000.000	Rp 12.417.778	0,5193	10	Lancar
Rp 558.800.000	60	Rp1.076.000.000	Rp 37.253.333	0,5193	10	Lancar
Rp 138.450.000	180	Rp 265.620.000	Rp 3.076.667	0,5212	3	Lancar
Rp 368.000.000	300	Rp 700.000.000	Rp 4.906.667	0,5257	4	Macet

## LAMPIRAN C

### HASIL UJI SENSITIVITAS

#### B.1 Sensitivitas Denda

Amatan	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1,0	2,0	5,0
1	0,757	0,756	0,756	0,755	0,754	0,753	0,753	0,752	0,751	0,750	0,743	0,721
2	0,688	0,686	0,685	0,684	0,683	0,682	0,681	0,680	0,679	0,678	0,668	0,640
3	0,680	0,680	0,679	0,678	0,677	0,677	0,676	0,675	0,675	0,674	0,667	0,647
4	0,672	0,672	0,671	0,671	0,670	0,670	0,669	0,669	0,668	0,668	0,663	0,649
5	0,655	0,654	0,654	0,653	0,652	0,652	0,651	0,650	0,650	0,649	0,643	0,625
6	0,654	0,653	0,652	0,651	0,649	0,648	0,647	0,646	0,645	0,644	0,633	0,603
7	0,477	0,477	0,477	0,476	0,476	0,476	0,475	0,475	0,475	0,474	0,471	0,462
8	0,470	0,470	0,469	0,469	0,468	0,468	0,468	0,467	0,467	0,467	0,463	0,452
9	0,466	0,466	0,465	0,465	0,464	0,464	0,464	0,463	0,463	0,462	0,458	0,447
10	0,461	0,461	0,460	0,459	0,459	0,458	0,457	0,457	0,456	0,455	0,449	0,431
11	0,459	0,459	0,459	0,459	0,459	0,458	0,458	0,458	0,458	0,457	0,455	0,448
12	0,458	0,458	0,457	0,457	0,456	0,456	0,455	0,455	0,454	0,454	0,450	0,437
13	0,455	0,454	0,454	0,453	0,453	0,453	0,452	0,452	0,451	0,451	0,447	0,435
14	0,450	0,449	0,449	0,448	0,448	0,447	0,447	0,446	0,446	0,445	0,441	0,427
15	0,440	0,440	0,439	0,439	0,438	0,438	0,437	0,437	0,436	0,436	0,431	0,418
16	0,422	0,422	0,421	0,420	0,419	0,418	0,418	0,417	0,416	0,415	0,407	0,386
17	0,402	0,401	0,400	0,399	0,398	0,397	0,396	0,395	0,394	0,393	0,384	0,359
18	0,396	0,395	0,395	0,395	0,395	0,394	0,394	0,394	0,394	0,393	0,391	0,383
19	0,380	0,379	0,379	0,379	0,379	0,379	0,378	0,378	0,378	0,378	0,376	0,370
20	0,377	0,376	0,376	0,376	0,375	0,375	0,375	0,374	0,374	0,374	0,370	0,361
21	0,373	0,372	0,372	0,372	0,371	0,371	0,371	0,370	0,370	0,370	0,367	0,358
22	0,371	0,371	0,371	0,370	0,370	0,370	0,369	0,369	0,369	0,368	0,365	0,357
23	0,369	0,368	0,368	0,368	0,368	0,367	0,367	0,367	0,367	0,367	0,364	0,358
24	0,363	0,362	0,362	0,361	0,361	0,361	0,360	0,360	0,359	0,359	0,355	0,343
25	0,353	0,353	0,352	0,352	0,352	0,351	0,351	0,351	0,350	0,350	0,347	0,338
26	0,354	0,353	0,352	0,352	0,351	0,350	0,349	0,349	0,348	0,347	0,340	0,320
27	0,351	0,351	0,351	0,350	0,350	0,350	0,350	0,349	0,349	0,349	0,347	0,341
28	0,353	0,353	0,352	0,352	0,351	0,351	0,350	0,350	0,349	0,349	0,345	0,332
29	0,345	0,344	0,344	0,343	0,343	0,342	0,342	0,341	0,341	0,340	0,335	0,321
30	0,344	0,343	0,343	0,343	0,342	0,342	0,342	0,341	0,341	0,341	0,337	0,328
31	0,342	0,342	0,342	0,342	0,341	0,341	0,341	0,341	0,340	0,340	0,338	0,331
32	0,328	0,327	0,327	0,326	0,326	0,325	0,325	0,325	0,324	0,324	0,319	0,306
33	0,328	0,327	0,327	0,327	0,327	0,326	0,326	0,326	0,325	0,325	0,322	0,314
34	0,324	0,323	0,323	0,322	0,321	0,320	0,319	0,318	0,317	0,316	0,308	0,285

## B.2 Sensitivitas Suku Bunga

Amatan	-0,4	-0,3	-0,2	-0,1	0,0	0,1	0,2	0,3	0,4	0,5	0,6	0,7
1	0,769	0,767	0,764	0,760	0,754	0,744	0,730	0,708	0,678	0,635	0,580	0,512
2	0,765	0,755	0,740	0,717	0,683	0,637	0,577	0,503	0,420	0,335	0,256	0,188
3	0,742	0,734	0,722	0,704	0,677	0,640	0,589	0,524	0,448	0,366	0,286	0,215
4	0,751	0,741	0,726	0,703	0,670	0,625	0,565	0,492	0,411	0,327	0,250	0,183
5	0,726	0,717	0,703	0,683	0,652	0,610	0,555	0,486	0,408	0,327	0,251	0,185
6	0,741	0,729	0,712	0,686	0,649	0,599	0,535	0,459	0,376	0,295	0,221	0,160
7	0,546	0,537	0,524	0,504	0,476	0,438	0,389	0,332	0,271	0,211	0,158	0,114
8	0,571	0,557	0,537	0,508	0,468	0,418	0,357	0,292	0,228	0,170	0,123	0,086
9	0,495	0,492	0,486	0,477	0,464	0,446	0,419	0,384	0,340	0,289	0,236	0,183
10	0,481	0,478	0,474	0,468	0,459	0,445	0,425	0,397	0,361	0,317	0,267	0,215
11	0,497	0,493	0,486	0,475	0,459	0,435	0,404	0,363	0,314	0,260	0,206	0,157
12	0,487	0,484	0,478	0,469	0,456	0,437	0,411	0,375	0,332	0,281	0,228	0,177
13	0,567	0,551	0,529	0,496	0,453	0,399	0,336	0,270	0,207	0,153	0,109	0,076
14	0,558	0,543	0,521	0,490	0,448	0,395	0,333	0,268	0,207	0,152	0,109	0,076
15	0,489	0,482	0,473	0,459	0,438	0,410	0,372	0,326	0,273	0,219	0,168	0,124
16	0,437	0,435	0,431	0,427	0,419	0,408	0,392	0,369	0,339	0,302	0,258	0,211
17	0,435	0,431	0,424	0,413	0,398	0,376	0,346	0,308	0,264	0,216	0,169	0,127
18	0,435	0,430	0,423	0,411	0,395	0,371	0,340	0,300	0,254	0,206	0,160	0,119
19	0,412	0,408	0,402	0,393	0,379	0,359	0,332	0,297	0,256	0,211	0,166	0,126
20	0,430	0,423	0,413	0,397	0,375	0,345	0,307	0,263	0,215	0,167	0,125	0,090
21	0,401	0,398	0,392	0,384	0,371	0,353	0,329	0,297	0,258	0,215	0,171	0,131
22	0,431	0,423	0,411	0,394	0,370	0,338	0,297	0,251	0,202	0,156	0,115	0,082
23	0,373	0,373	0,372	0,370	0,368	0,364	0,358	0,350	0,338	0,321	0,298	0,269
24	0,389	0,386	0,381	0,373	0,361	0,344	0,320	0,290	0,253	0,211	0,168	0,129
25	0,375	0,373	0,368	0,362	0,352	0,337	0,317	0,290	0,256	0,218	0,177	0,137
26	0,388	0,384	0,377	0,366	0,351	0,329	0,300	0,265	0,223	0,180	0,139	0,103
27	0,447	0,433	0,414	0,386	0,350	0,305	0,255	0,203	0,154	0,113	0,080	0,055
28	0,397	0,391	0,383	0,370	0,351	0,326	0,293	0,253	0,209	0,165	0,125	0,091
29	0,391	0,385	0,376	0,362	0,343	0,317	0,283	0,243	0,199	0,156	0,117	0,085
30	0,390	0,384	0,375	0,362	0,342	0,316	0,282	0,242	0,198	0,155	0,116	0,084
31	0,366	0,363	0,359	0,352	0,341	0,326	0,305	0,278	0,244	0,205	0,165	0,127
32	0,343	0,341	0,338	0,333	0,326	0,315	0,300	0,279	0,251	0,218	0,182	0,145
33	0,378	0,371	0,362	0,347	0,327	0,299	0,264	0,224	0,182	0,140	0,104	0,075
34	0,366	0,361	0,352	0,339	0,321	0,296	0,264	0,226	0,185	0,145	0,109	0,079
35	0,415	0,400	0,378	0,348	0,310	0,264	0,215	0,167	0,124	0,089	0,062	0,043
36	0,481	0,453	0,415	0,366	0,309	0,249	0,191	0,140	0,099	0,069	0,047	0,031
37	0,403	0,389	0,369	0,341	0,305	0,261	0,214	0,167	0,125	0,090	0,063	0,043
38	0,313	0,311	0,307	0,302	0,294	0,283	0,267	0,246	0,219	0,187	0,153	0,120

### B3. Sensitivitas Tenor

Amatan	24	30	36	44	50	54	60	66	72	78	84	120
1	0,768	0,767	0,765	0,760	0,754	0,748	0,735	0,714	0,682	0,635	0,570	0,089
2	0,763	0,755	0,743	0,716	0,683	0,654	0,596	0,520	0,430	0,335	0,244	0,016
3	0,741	0,734	0,725	0,704	0,677	0,653	0,605	0,539	0,458	0,366	0,275	0,019
4	0,749	0,741	0,729	0,702	0,670	0,641	0,584	0,509	0,421	0,327	0,239	0,016
5	0,725	0,717	0,706	0,682	0,652	0,626	0,572	0,502	0,418	0,327	0,240	0,016
6	0,739	0,730	0,716	0,685	0,649	0,617	0,555	0,477	0,386	0,294	0,211	0,013
7	0,544	0,537	0,527	0,503	0,476	0,451	0,404	0,345	0,279	0,211	0,150	0,009
8	0,568	0,558	0,542	0,507	0,468	0,435	0,375	0,306	0,235	0,170	0,116	0,007
9	0,494	0,492	0,487	0,477	0,464	0,453	0,428	0,393	0,346	0,289	0,227	0,019
10	0,480	0,478	0,475	0,468	0,459	0,450	0,431	0,404	0,366	0,317	0,259	0,024
11	0,496	0,493	0,487	0,474	0,459	0,444	0,414	0,373	0,321	0,260	0,198	0,015
12	0,487	0,484	0,479	0,469	0,456	0,444	0,419	0,384	0,337	0,281	0,220	0,018
13	0,564	0,552	0,534	0,495	0,453	0,418	0,355	0,285	0,215	0,153	0,103	0,006
14	0,556	0,544	0,526	0,489	0,448	0,413	0,352	0,283	0,214	0,152	0,103	0,006
15	0,487	0,483	0,475	0,458	0,438	0,420	0,384	0,337	0,280	0,219	0,161	0,011
16	0,436	0,435	0,432	0,426	0,419	0,412	0,397	0,375	0,344	0,302	0,251	0,025
17	0,434	0,431	0,425	0,413	0,398	0,384	0,356	0,317	0,270	0,216	0,162	0,012
18	0,434	0,431	0,424	0,411	0,395	0,380	0,350	0,309	0,260	0,206	0,153	0,011
19	0,412	0,408	0,404	0,392	0,379	0,366	0,341	0,306	0,262	0,211	0,160	0,012
20	0,429	0,423	0,415	0,397	0,375	0,356	0,319	0,273	0,220	0,167	0,119	0,007
21	0,400	0,398	0,393	0,383	0,371	0,360	0,337	0,305	0,263	0,215	0,165	0,012
22	0,429	0,423	0,414	0,394	0,370	0,349	0,310	0,262	0,208	0,156	0,110	0,007
23	0,373	0,373	0,372	0,370	0,368	0,365	0,360	0,352	0,340	0,321	0,294	0,054
24	0,389	0,386	0,382	0,373	0,361	0,350	0,328	0,297	0,257	0,211	0,162	0,012
25	0,375	0,373	0,369	0,361	0,352	0,343	0,324	0,297	0,261	0,218	0,171	0,014
26	0,388	0,384	0,378	0,366	0,351	0,337	0,310	0,273	0,229	0,180	0,133	0,009
27	0,444	0,434	0,418	0,386	0,350	0,321	0,270	0,214	0,160	0,112	0,075	0,004
28	0,396	0,392	0,385	0,369	0,351	0,335	0,303	0,262	0,214	0,165	0,119	0,008
29	0,390	0,385	0,378	0,362	0,343	0,326	0,293	0,252	0,204	0,156	0,112	0,007
30	0,389	0,385	0,377	0,361	0,342	0,325	0,292	0,251	0,203	0,155	0,111	0,007
31	0,366	0,363	0,360	0,352	0,341	0,332	0,312	0,284	0,248	0,205	0,159	0,012
32	0,343	0,341	0,339	0,333	0,326	0,319	0,305	0,284	0,255	0,218	0,176	0,016
33	0,377	0,372	0,364	0,347	0,327	0,309	0,275	0,233	0,187	0,140	0,099	0,006
34	0,365	0,361	0,354	0,339	0,321	0,305	0,274	0,235	0,190	0,145	0,104	0,006
35	0,412	0,400	0,383	0,347	0,310	0,280	0,230	0,177	0,129	0,089	0,059	0,003
36	0,476	0,454	0,423	0,365	0,309	0,269	0,207	0,151	0,104	0,069	0,044	0,002
37	0,401	0,390	0,373	0,340	0,305	0,276	0,228	0,177	0,130	0,090	0,059	0,003
38	0,312	0,311	0,308	0,302	0,294	0,287	0,272	0,251	0,222	0,187	0,148	0,012

## B.4 Sensitivitas *Cashback*

Amatan	6%	7%	8%	9%	10%	11%	12%	13%	14%	15%
1	0,767	0,764	0,760	0,757	0,754	0,751	0,748	0,744	0,741	0,738
2	0,692	0,690	0,688	0,686	0,683	0,681	0,679	0,677	0,675	0,673
3	0,695	0,690	0,686	0,682	0,677	0,673	0,669	0,665	0,660	0,656
4	0,683	0,680	0,677	0,673	0,670	0,667	0,664	0,660	0,657	0,654
5	0,665	0,662	0,659	0,655	0,652	0,649	0,646	0,643	0,640	0,637
6	0,663	0,660	0,656	0,653	0,649	0,646	0,643	0,639	0,636	0,632
7	0,493	0,489	0,485	0,480	0,476	0,472	0,467	0,463	0,458	0,454
8	0,481	0,478	0,475	0,472	0,468	0,465	0,462	0,459	0,456	0,452
9	0,476	0,473	0,470	0,467	0,464	0,461	0,459	0,456	0,453	0,450
10	0,470	0,467	0,464	0,461	0,459	0,456	0,453	0,450	0,448	0,445
11	0,469	0,466	0,464	0,461	0,459	0,456	0,453	0,451	0,448	0,446
12	0,470	0,467	0,463	0,460	0,456	0,453	0,449	0,446	0,442	0,439
13	0,465	0,462	0,459	0,456	0,453	0,450	0,447	0,444	0,441	0,437
14	0,463	0,459	0,455	0,451	0,448	0,444	0,440	0,436	0,433	0,429
15	0,450	0,447	0,444	0,441	0,438	0,436	0,433	0,430	0,427	0,424
16	0,432	0,429	0,426	0,422	0,419	0,416	0,413	0,409	0,406	0,403
17	0,408	0,406	0,403	0,400	0,398	0,395	0,393	0,390	0,387	0,385
18	0,409	0,406	0,402	0,398	0,395	0,391	0,387	0,383	0,380	0,376
19	0,389	0,387	0,384	0,382	0,379	0,376	0,374	0,371	0,368	0,366
20	0,387	0,384	0,381	0,378	0,375	0,372	0,370	0,367	0,364	0,361
21	0,380	0,378	0,376	0,374	0,371	0,369	0,367	0,365	0,362	0,360
22	0,381	0,379	0,376	0,373	0,370	0,367	0,364	0,361	0,359	0,356
23	0,378	0,376	0,373	0,370	0,368	0,365	0,362	0,360	0,357	0,354
24	0,368	0,367	0,365	0,363	0,361	0,359	0,357	0,355	0,354	0,352
25	0,362	0,359	0,357	0,354	0,352	0,349	0,347	0,344	0,342	0,339
26	0,363	0,360	0,357	0,354	0,351	0,348	0,345	0,342	0,339	0,336
27	0,364	0,360	0,357	0,354	0,350	0,347	0,343	0,340	0,337	0,333
28	0,370	0,365	0,361	0,356	0,351	0,347	0,342	0,337	0,333	0,328
29	0,355	0,352	0,349	0,346	0,343	0,340	0,337	0,334	0,331	0,328
30	0,355	0,352	0,348	0,345	0,342	0,339	0,336	0,333	0,330	0,327
31	0,358	0,354	0,350	0,345	0,341	0,337	0,333	0,329	0,325	0,321
32	0,338	0,335	0,332	0,329	0,326	0,323	0,320	0,317	0,314	0,311
33	0,341	0,337	0,334	0,330	0,327	0,323	0,319	0,316	0,312	0,308
34	0,333	0,330	0,327	0,324	0,321	0,318	0,314	0,311	0,308	0,305
35	0,319	0,317	0,314	0,312	0,310	0,307	0,305	0,303	0,300	0,298
36	0,323	0,319	0,316	0,312	0,309	0,306	0,302	0,299	0,296	0,292
37	0,315	0,312	0,310	0,307	0,305	0,302	0,300	0,297	0,295	0,292
38	0,301	0,300	0,298	0,296	0,294	0,293	0,291	0,289	0,287	0,285

*Halaman ini sengaja dikosongkan*

## BIODATA PENULIS



Penulis yang memiliki nama lengkap Oryza Akbar Rochmadhan, dilahirkan di Surabaya pada 20 Oktober 1995. Anak kedua dari dua bersaudara yang telah menempuh pendidikan di SDN Kedungdoro V Surabaya (2001-2007), SMPN 1 Surabaya (2007-2010), SMAN 5 Surabaya (2010-2013), dan Teknik Industri Institut Teknologi Sepuluh Nopember (ITS) Surabaya (2013-2017).

Selama perkuliahan, penulis cukup aktif dalam unit kegiatan mahasiswa *bridge*. Selama mengikuti UKM *Bridge*, penulis berhasil menjuarai kejuaraan nasional *bridge* tingkat mahasiswa. Penulis juga pernah melaksanakan kerja praktek di PT. Telekomunikasi Indonesia. *Email*: oryza.akbar@gmail.com