



TUGAS AKHIR - SS141501

**PREDIKSI *FINANCIAL DISTRESS* BANK UMUM DI
INDONESIA DENGAN METODE *GENERALIZED
EXTREME VALUE REGRESSION*, REGRESI
LOGISTIK, DAN ANALISIS DISKRIMINAN KERNEL**

**ADRIANI WIDYARANI
NRP 1314 100 106**

Dosen Pembimbing
Dr. rer. pol. Dedy Dwi Prastyo, S.Si., M.Si.

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2018**



TUGAS AKHIR - SS141501

**PREDIKSI *FINANCIAL DISTRESS* BANK UMUM
DI INDONESIA DENGAN METODE *GENERALIZED
EXTREME VALUE REGRESSION*, REGRESI
LOGISTIK, DAN ANALISIS DISKRIMINAN KERNEL**

**ADRIANI WIDYARANI
NRP 1314 100 106**

**Dosen Pembimbing
Dr. rer. pol. Dedy Dwi Prastyo, S.Si., M.Si.**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2018**



FINAL PROJECT - SS 141501

***FINANCIAL DISTRESS PREDICTION OF
COMMERCIAL BANK IN INDONESIA USING
GENERALIZED EXTREME VALUE REGRESSION,
LOGISTIC REGRESSION, AND KERNEL
DISCRIMINANT ANALYSIS***

**ADRIANI WIDYARANI
NRP 1314 100 106**

**Supervisor
Dr. rer. pol. Dedy Dwi Prastyo, S.Si., M.Si.**

**UNDERGRADUATE PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS, COMPUTING, AND DATA SCIENCE
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2018**

LEMBAR PENGESAHAN

**PREDIKSI *FINANCIAL DISTRESS* BANK UMUM
DI INDONESIA DENGAN METODE *GENERALIZED
EXTREME VALUE REGRESSION*, REGRESI LOGISTIK,
DAN ANALISIS DISKRIMINAN KERNEL**

TUGAS AKHIR

Diajukan untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada
Program Studi Sarjana Departemen Statistika
Fakultas Matematika, Komputasi, dan Sains Data
Institut Teknologi Sepuluh Nopember

Oleh :

Adriani Widyanani

NRP. 1314 100 106

Disetujui oleh Pembimbing Tugas Akhir :

Dr. rer. pol. Dedy Dwi Prastyo, S.Si., M.Si.

NIP. 19831204 200812 1 002



Mengetahui,
Kepala Departemen



Dr. Suhartono

NIP. 19740929 199512 1 001

SURABAYA, JANUARI 2018

(Halaman ini sengaja dikosongkan)

PREDIKSI *FINANCIAL DISTRESS* BANK UMUM DI INDONESIA DENGAN METODE *GENERALIZED EXTREME VALUE REGRESSION*, REGRESI LOGISTIK, DAN ANALISIS DISKRIMINAN KERNEL

Nama Mahasiswa : Adriani Widyarani
NRP : 1314 100 106
Departemen : Statistika
Dosen Pembimbing : Dr. rer. pol. Dedy Dwi Prastyo, S.Si., M.Si.

Abstrak

Stabilitas sistem keuangan telah menjadi perhatian pemerintah dan pihak-pihak terkait. Secara umum, stabilitas sistem keuangan ditopang oleh dua pilar utama yaitu stabilitas harga dan stabilitas sektor keuangan. Perbankan merupakan sektor yang sejauh ini mendominasi sektor keuangan Indonesia. Namun, sektor perbankan cenderung rentan terhadap gangguan. Penelitian ini bertujuan untuk memprediksi kondisi financial distress bank umum di Indonesia dengan metode analisis diskriminan, regresi logistik dan generalized extreme value regression. Pemodelan dilakukan secara univariat, serentak, dan dengan menggunakan seleksi variabel. Regresi logistik mampu menghasilkan nilai AUC tertinggi pada pemodelan yang dilakukan secara univariat dan stepwise. Namun, GEVR mampu menghasilkan AUC yang tinggi dengan lebih banyak variabel yang signifikan apabila pemodelan dilakukan secara serentak. Metode GEVR menghasilkan dua variabel yang signifikan pada window size 1 dan satu variabel signifikan pada window size 3, sedangkan metode regresi logistik tidak menghasilkan variabel yang signifikan apabila pemodelan dilakukan secara serentak.

Kata Kunci: *Analisis Diskriminan Kernel, Bank Umum, Financial Distress, Generalized Extreme Value Regression, Regresi Logistik*

(Halaman ini sengaja dikosongkan)

FINANCIAL DISTRESS PREDICTION OF COMMERCIAL BANK IN INDONESIA USING GENERALIZED EXTREME VALUE REGRESSION, LOGISTIC REGRESSION, AND KERNEL DISCRIMINANT ANALYSIS

Name : Adriani Widyarani
NRP : 1314 100 106
Department : Statistics
Supervisor : Dr. rer. pol. Dedy Dwi Prastyo, S.Si., M.Si.

Abstract

The stability of financial system has been the concern of Indonesian government and related parties. In general, the stability of the financial system is sustained by two main things. They are the stability of Indonesian market and the stability of Indonesian financial sector. In Indonesia, the banking sector is the biggest sector in financial industries. However, the banking sector tends to be risky to disruption. The aim of this research is to predict the financial distress in Indonesian commercial bank using discriminant analysis, logistic regression, and generalized extreme value regression. Modelling is done by using three alternatives, they are univariate modelling, multivariate modelling, and modelling by using variable selection. Logistic regression produces the highest AUC value when univariate modelling or stepwise method is performed. However, GEVR produces high AUC value with more significant variables when the multivariate modelling is performed. The GEVR method produces two significant variables in window size 1 and one variable in window size 3, whereas logistic regression does not produce any significant variables.

Keywords: *Commercial Bank, Financial Distress Generalized Extreme Value Regression, Kernel Discriminant Analysis, Logistic Regression*

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur penulis panjatkan kehadirat Allah SWT, karena atas rahmat-Nya lah peneliti dapat menyelesaikan Tugas Akhir yang berjudul “**Prediksi *Financial Distress* Bank Umum di Indonesia dengan Metode *Generalized Extreme Value Regression*, Regresi Logistik, dan Analisis Diskriminan Kernel**”. Penulis menyadari selama proses pengerjaan Tugas Akhir tidak terlepas dari bantuan berbagai pihak. Oleh karena itu, penulis ingin mengucapkan terimakasih kepada:

1. Dr. rer. pol Dedy Dwi Prastyo, S.Si., M.Si. selaku dosen pembimbing yang telah bersedia meluangkan waktunya untuk memberikan bimbingan, saran serta dukungan dengan sabar selama proses penyelesaian Tugas Akhir.
2. Dr. Suhartono selaku dosen penguji dan Kepala Departemen Statistika FMKSD-ITS dan Dr. rer. pol Heri Kuswanto, S.Si., M.Si. selaku dosen penguji yang telah banyak memberi masukan kepada penulis.
3. Dr. Sutikno, M.Si. selaku Ketua Prodi Sarjana Departemen Statistika FMKSD-ITS yang telah memfasilitasi penulis selama proses perkuliahan.
4. Dr. Bambang Widjanarko Otok, M.Si. selaku dosen wali yang telah banyak memberikan arahan selama proses perkuliahan penulis.
5. Kedua orang tua serta kedua saudara penulis yang senantiasa memberikan doa dan dukungan kepada penulis.
6. Seluruh pihak yang membantu penulis selama proses perkuliahan dan proses pengerjaan Tugas Akhir.

Penulis sangat mengharapkan kritik dan saran untuk membuat Tugas Akhir ini lebih baik. Besar harapan penulis agar Tugas Akhir ini bermanfaat bagi seluruh pihak.

Surabaya, Januari 2018

Penulis

(Halaman ini sengaja dikosongkan)

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
COVER PAGE	iii
LEMBAR PENGESAHAN	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xv
DAFTAR TABEL	xix
DAFTAR LAMPIRAN	xxiii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	6
1.3 Tujuan Penelitian	6
1.4 Manfaat Penelitian	6
1.5 Batasan Masalah	7
BAB II TINJAUAN PUSTAKA	9
2.1 Imputasi <i>k</i> -Nearest Neighbor	9
2.2 Analisis Diskriminan	10
2.3 Analisis Diskriminan Kernel	14
2.4 Regresi Logistik	15
2.5 <i>Extreme Value Theory</i>	16
2.6 <i>Generalized Extreme Value Distribution</i> ...	18
2.7 <i>Generalized Extreme Value Regression</i>	19
2.8 Estimasi Parameter	20
2.9 Uji Signifikansi Parameter	24
2.10 Evaluasi Model	24
2.11 Konsep <i>Drift</i>	27
2.12 Laporan Keuangan Bank	29
2.13 Rasio Keuangan Bank	29
2.14 Kondisi Makroekonomi	32
2.15 <i>Financial Distress</i>	32

BAB III METODOLOGI PENELITIAN	35
3.1 Sumber Data	35
3.2 Variabel Penelitian.....	35
3.3 Struktur Data.....	36
3.4 Langkah Analisis	36
BAB IV ANALISIS DAN PEMBAHASAN	43
4.1 Imputasi <i>Missing Value</i> Pada Data Rasio Perbankan dan Kondisi Makroekonomi Indonesia.....	43
4.2 Karakteristik Rasio Perbankan dan Kondisi Makroekonomi Indonesia.....	44
4.3 <i>Window Size</i> Pada Data Kondisi Keuangan Perbankan	66
4.4 Pemodelan Prediksi <i>Financial Distress</i> dengan Analisis Diskriminan	69
4.5 Pemodelan Prediksi <i>Financial Distress</i> dengan Regresi Logistik.....	88
4.6 Pemodelan Prediksi <i>Financial Distress</i> dengan <i>Generalized Extreme Value</i> Regression.....	101
4.7 Perbandingan Keباikan Model	114
BAB V KESIMPULAN DAN SARAN	117
5.1 Kesimpulan	117
5.2 Saran	118
DAFTAR PUSTAKA	119
LAMPIRAN	123

DAFTAR GAMBAR

		Halaman
Gambar 2.1	<i>Probability Density Function</i> dari Distribusi Weibull (<i>dashed</i>), Distribusi Gumbel (<i>solid</i>), dan Distribusi Frechet (<i>dotted</i>)	17
Gambar 2.2	Skema <i>Block Maxima</i> dan <i>Peak Over Threshold</i>	18
Gambar 2.3	Kurva ROC.....	26
Gambar 2.4	Skema <i>Full Memory Time Window</i> dan <i>No Memory Time Window</i>	28
Gambar 3.1	Diagram Alir	38
Gambar 3.2	Diagram Alir Analisis Diskriminan	39
Gambar 3.3	Diagram Alir Regresi Logistik	40
Gambar 3.4	Diagram Alir <i>Generalized Extreme Value Regression</i>	41
Gambar 4.1	Tingkat Inflasi YoY Indonesia Tahun 2004-2008.....	44
Gambar 4.2	Pertumbuhan Ekonomi Indonesia Tahun 2004-2008.....	45
Gambar 4.3	Rata-Rata Prosentase NPL Bank Sehat dan Prosentase NPL Bank dengan <i>Financial Distress</i>	46
Gambar 4.4	<i>Dot Plot</i> NPL Bank Umum Tahun 2004-2008.....	47
Gambar 4.5	Rata-Rata Prosentase CAR Bank Sehat dan Prosentase CAR Bank dengan <i>Financial Distress</i>	48
Gambar 4.6	<i>Dot Plot</i> CAR Bank Umum Tahun 2004-2008.....	49
Gambar 4.7	Rata-Rata Prosentase LDR Bank Sehat dan Prosentase LDR Bank dengan <i>Financial Distress</i>	50

Gambar 4.8	<i>Dot Plot</i> LDR Bank Umum Tahun 2004-2008.....	51
Gambar 4.9	Rata-Rata Prosentase ROA Bank Sehat dan Prosentase ROA Bank dengan <i>Financial Distress</i>	52
Gambar 4.10	<i>Dot Plot</i> ROA Bank Umum Tahun 2004-2008.....	53
Gambar 4.11	Rata-Rata Prosentase ROE Bank Sehat dan Prosentase ROE Bank dengan <i>Financial Distress</i>	53
Gambar 4.12	<i>Dot Plot</i> ROE Bank Umum Tahun 2004-2008.....	55
Gambar 4.13	Rata-Rata Prosentase NIM Bank Sehat dan Prosentase NIM Bank dengan <i>Financial Distress</i>	56
Gambar 4.14	<i>Dot Plot</i> NIM Bank Umum Tahun 2004-2008.....	57
Gambar 4.15	Rata-Rata Prosentase BOPO Bank Sehat dan Prosentase BOPO Bank dengan <i>Financial Distress</i>	58
Gambar 4.16	<i>Dot Plot</i> BOPO Bank Umum Tahun 2004-2008.....	59
Gambar 4.17	Rata-Rata Prosentase Aktiva Produktif Bermasalah Prosentase Aktiva Produktif Bermasalah Bank Sehat dan Bank dengan <i>Financial Distress</i>	60
Gambar 4.18	<i>Dot Plot</i> Aktiva Produktif Bermasalah Bank Umum Tahun 2004-2008	61
Gambar 4.19	Rata-Rata Prosentase PPAP Terhadap Aktiva Produktif Bank Sehat dan Prosentase PPAP Terhadap Aktiva Produktif Bank dengan <i>Financial Distress</i>	62

Gambar 4.20	<i>Dot Plot</i> PPAP Terhadap Aktiva Produktif Bank Umum Tahun 2004-2008.....	63
Gambar 4.21	Rata-Rata Prosentase Pemenuhan PPAP Bank Sehat dan Prosentase Pemenuhan PPAP Bank dengan <i>Financial Distress</i>	64
Gambar 4.22	<i>Dot Plot</i> Pemenuhan PPAP Bank Umum Tahun 2004-2008	65
Gambar 4.23	Rata-Rata Prosentase ATTM Bank Sehat dan Prosentase ATTM Bank dengan <i>Financial Distress</i>	66
Gambar 4.24	<i>Dot Plot</i> ATTM Bank Umum Tahun 2004-2008.....	67
Gambar 4.25	<i>Full Memory Time Window</i> Untuk <i>Size</i> = 1	68
Gambar 4.26	<i>Full Memory Time Window</i> Untuk <i>Size</i> = 2	68
Gambar 4.27	<i>Full Memory Time Window</i> Untuk <i>Size</i> = 3	69
Gambar 4.28	<i>Heatmap</i> Rasio Keuangan Bank	69
Gambar 4.29	<i>Chi-Squared QQ-Plot</i> Data Rasio Keuangan, Inflasi, dan Pertumbuhan Ekonomi	71
Gambar 4.30	Nilai Akurasi Metode Analisis Diskriminan Linier	75
Gambar 4.31	Nilai Akurasi Metode Analisis Diskriminan Linier dengan <i>Stepwise</i>	85
Gambar 4.32	Nilai Akurasi Metode Analisis Diskriminan Kernel	87
Gambar 4.33	Nilai Akurasi Metode Analisis Diskriminan Kernel dengan <i>Stepwise</i>	89
Gambar 4.34	Nilai Akurasi Metode Regresi Logistik Biner	92
Gambar 4.35	Nilai Akurasi Metode Regresi Logistik Biner dengan <i>Stepwise</i>	103

Gambar 4.36	Nilai Akurasi Metode GEVR.....	106
Gambar 4.37	Nilai Akurasi Metode GEVR dengan <i>Stepwise</i>	116
Gambar 4.38	Perbandingan AUC Data <i>Training</i> Regresi Logistik dan GEVR	119

DAFTAR TABEL

	Halaman
Tabel 2.1	<i>Distribution of Wilks' Lambda</i> 14
Tabel 2.2	<i>Confussion Matrix</i>25
Tabel 2.3	Kategori Keباikan Model Berdasarkan AUC..27
Tabel 3.1	Variabel Penelitian35
Tabel 3.2	Struktur Data36
Tabel 4.1	Jumlah <i>Missing Value</i> Data43
Tabel 4.2	Hasil Uji Beda Rata-Rata Antar Kelompok..... 72
Tabel 4.3	Model Prediksi <i>Financial Distress</i> dengan Analisis Diskriminan Linier Secara Serentak ..73
Tabel 4.4	Variabel yang Berpengaruh Signifikan Pada Metode Analisis Diskriminan Secara Serentak 74
Tabel 4.5	Ketepatan Klasifikasi Analisis Diskriminan Linier 74
Tabel 4.6	Model Prediksi <i>Financial Distress</i> dengan Analisis Diskriminan Linier Secara Univariat Pada <i>Size 0</i>76
Tabel 4.7	Ketepatan Klasifikasi Analisis Diskriminan Linier Secara Univariat Pada <i>Size 0</i>77
Tabel 4.8	Model Prediksi <i>Financial Distress</i> dengan Analisis Diskriminan Linier Secara Univariat Pada <i>Size 1</i> 78
Tabel 4.9	Ketepatan Klasifikasi Analisis Diskriminan Linier Secara Univariat Pada <i>Size 1</i>79
Tabel 4.10	Model Prediksi <i>Financial Distress</i> dengan Analisis Diskriminan Linier Secara Univariat Pada <i>Size 2</i>80
Tabel 4.11	Ketepatan Klasifikasi Analisis Diskriminan Linier Secara Univariat Pada <i>Size 2</i>81
Tabel 4.12	Model Prediksi <i>Financial Distress</i> dengan Analisis Diskriminan Linier Secara Univariat Pada <i>Size 3</i>82
Tabel 4.13	Ketepatan Klasifikasi Analisis Diskriminan Linier Secara Univariat Pada <i>Size 3</i>82

Tabel 4.14	Variabel Terpilih Pada Analisis Diskriminan Linier	83
Tabel 4.15	Model Prediksi <i>Financial Distress</i> Pada Analisis Diskriminan Linier dengan <i>Stepwise</i>	83
Tabel 4.16	Ketepatan Klasifikasi Analisis Diskriminan Linier dengan <i>Stepwise</i>	84
Tabel 4.17	Variabel yang Berpengaruh Signifikan Pada Metode Analisis Diskriminan Kernel Secara Serentak	86
Tabel 4.18	Ketepatan Klasifikasi Analisis Diskriminan Kernel	86
Tabel 4.19	Variabel Terpilih Pada Analisis Diskriminan Kernel	88
Tabel 4.20	Ketepatan Klasifikasi Analisis Diskriminan Kernel dengan <i>Stepwise</i>	89
Tabel 4.21	Model Prediksi <i>Financial Distress</i> dengan Regresi Logistik Biner Secara Serentak	91
Tabel 4.22	Ketepatan Klasifikasi Regresi Logistik Biner Secara Serentak	91
Tabel 4.23	Model Prediksi <i>Financial Distress</i> dengan Regresi Logistik Biner Secara Univariat Pada <i>Size 0</i>	93
Tabel 4.24	Ketepatan Klasifikasi Regresi Logistik Biner Univariat Pada <i>Size 0</i>	95
Tabel 4.25	Model Prediksi <i>Financial Distress</i> dengan Regresi Logistik Biner Secara Univariat Pada <i>Size 1</i>	96
Tabel 4.26	Ketepatan Klasifikasi Regresi Logistik Biner Univariat Pada <i>Size 1</i>	97
Tabel 4.27	Model Prediksi <i>Financial Distress</i> dengan Regresi Logistik Biner Secara Univariat Pada <i>Size 2</i>	98
Tabel 4.28	Ketepatan Klasifikasi Regresi Logistik Biner Univariat Pada <i>Size 2</i>	99

Tabel 4.29	Model Prediksi <i>Financial Distress</i> dengan Regresi Logistik Biner Secara Univariat Pada <i>Size 0</i>	99
Tabel 4.30	Ketepatan Klasifikasi Regresi Logistik Biner Univariat Pada <i>Size 0</i>	100
Tabel 4.31	Variabel Terpilih Pada Regresi Logistik Biner	101
Tabel 4.32	Model Prediksi <i>Financial Distress</i> Pada Regresi Logistik Biner dengan <i>Stepwise</i>	102
Tabel 4.33	Ketepatan Klasifikasi Regresi Logistik Biner dengan <i>Stepwise</i>	103
Tabel 4.34	Model Prediksi <i>Financial Distress</i> dengan GEVR	104
Tabel 4.35	Variabel yang Berpengaruh Secara Signifikan Pada Metode GEVR	105
Tabel 4.36	Ketepatan Klasifikasi GEVR Secara Serentak.	105
Tabel 4.37	Model Prediksi <i>Financial Distress</i> dengan GEVR Secara Univariat Pada <i>Size 0</i>	107
Tabel 4.38	Ketepatan Klasifikasi GEVR Univariat Pada <i>Size 0</i>	108
Tabel 4.39	Model Prediksi <i>Financial Distress</i> dengan GEVR Secara Univariat Pada <i>Size 1</i>	109
Tabel 4.40	Ketepatan Klasifikasi GEVR Univariat Pada <i>Size 1</i>	110
Tabel 4.41	Model Prediksi <i>Financial Distress</i> dengan GEVR Secara Univariat Pada <i>Size 2</i>	111
Tabel 4.42	Ketepatan Klasifikasi GEVR Univariat Pada <i>Size 2</i>	112
Tabel 4.43	Model Prediksi <i>Financial Distress</i> dengan GEVR Secara Univariat Pada <i>Size 3</i>	113
Tabel 4.44	Ketepatan Klasifikasi GEVR Univariat Pada <i>Size 3</i>	114
Tabel 4.45	Variabel Terpilih Pada GEVR	115
Tabel 4.46	Model Prediksi <i>Financial Distress</i> dengan GEVR Menggunakan <i>Stepwise</i>	115
Tabel 4.47	Ketepatan Klasifikasi GEVR dengan <i>Stepwise</i>	116

Tabel 4.48	Perbandingan AUC Data <i>Training</i>	117
Tabel 4.49	Perbandingan AUC Data <i>Testing</i>	118
Tabel 4.50	Perbandingan Jumlah Variabel Signifikan Secara Serentak	119
Tabel 4.51	Perbandingan Jumlah Variabel Signifikan Secara Univariate.....	120
Tabel 4.52	Perbandingan AUC Data <i>Training</i> Model Univariat Pada <i>Size</i> 0	121
Tabel 4.53	Perbandingan AUC Data <i>Testing</i> Model Univariat Pada <i>Size</i> 0	122
Tabel 4.54	Perbandingan AUC Data <i>Training</i> Model Univariat Pada <i>Size</i> 1	123
Tabel 4.55	Perbandingan AUC Data <i>Testing</i> Model Univariat Pada <i>Size</i> 1	124
Tabel 4.56	Perbandingan AUC Data <i>Training</i> Model Univariat Pada <i>Size</i> 2	125
Tabel 4.57	Perbandingan AUC Data <i>Testing</i> Model Univariat Pada <i>Size</i> 2	126
Tabel 4.58	Perbandingan AUC Data <i>Training</i> Model Univariat Pada <i>Size</i> 0	127
Tabel 4.59	Perbandingan AUC Data <i>Testing</i> Model Univariat Pada <i>Size</i> 0	128
Tabel 4.60	Perbandingan Jumlah Variabel Signifikan dengan <i>Stepwise</i>	129
Tabel 4.61	Perbandingan AUC Data <i>Training</i> dengan <i>Stepwise</i>	129
Tabel 4.62	Perbandingan AUC Data <i>Testing</i> dengan <i>Stepwise</i>	130

DAFTAR LAMPIRAN

	Halaman
Lampiran 1	Data Rasio Keuangan Bank dan Kondisi Ekonomi Indonesia 2004-2008 .. 137
Lampiran 2	Hasil <i>Box's M Test</i> 138
Lampiran 3	Hasil Uji Distribusi Normal Multivariat .. 138
Lampiran 4	Hasil Uji Beda Rata-Rata Antar Kelompok Secara Serentak..... 139
Lampiran 5	Hasil Uji Beda Rata-Rata Antar Kelompok Secara Parsial..... 140
Lampiran 6	Uji Signifikansi Parameter Analisis Diskriminan Linier 144
Lampiran 7	<i>Confussion Matrix</i> Klasifikasi dengan Metode Analisis Diskriminan Linier Secara Serentak 148
Lampiran 8	Kurva ROC Klasifikasi dengan Metode Analisis Diskriminan Linier 150
Lampiran 9	Variabel Terpilih Pada Analisis Diskriminan <i>Stepwise</i> 152
Lampiran 10	<i>Confussion Matrix</i> Analisis Diskriminan <i>Stepwise</i> 155
Lampiran 11	Kurva ROC Analisis Diskriminan <i>Stepwise</i> 157
Lampiran 12	<i>Confussion Matrix</i> Analisis Diskriminan Univariate <i>Size = 0</i> 159
Lampiran 13	Uji Signifikansi Parameter Analisis Diskriminan Univariate <i>Size = 0</i> 173
Lampiran 14	<i>Confussion Matrix</i> Analisis Diskriminan Univariate <i>Size = 1</i> 177
Lampiran 15	<i>Confussion Matrix</i> Analisis Diskriminan Univariate <i>Size = 2</i> 177
Lampiran 16	<i>Confussion Matrix</i> Analisis Diskriminan Univariate <i>Size = 3</i> 179
Lampiran 17	<i>Kernel Fisher Discriminant Plot</i> 185

Lampiran 18	<i>Confussion Matrix</i> Klasifikasi dengan Metode Analisis Diskriminan Kernel	186
Lampiran 19	Kurva ROC Klasifikasi dengan Metode Analisis Diskriminan Kernel	188
Lampiran 20	Estimasi Parameter Model Prediksi <i>Financial Distress</i> dengan Regresi Logistik Biner.....	190
Lampiran 21	<i>Odds Ratio</i> Model Prediksi <i>Financial Distress</i> dengan Regresi Logistik Biner...	194
Lampiran 22	<i>Confussion Matrix</i> Klasifikasi dengan Metode Regresi Logistik Biner.....	198
Lampiran 23	Kurva ROC Klasifikasi dengan Metode Regresi Logistik Biner.....	200
Lampiran 24	Kurva ROC Regresi Logistik <i>Stepwise</i>	202
Lampiran 25	<i>Confussion Matrix</i> Regresi Logistik Univariat <i>Size</i> = 0	204
Lampiran 26	<i>Confussion Matrix</i> Regresi Logistik Univariat <i>Size</i> = 1	210
Lampiran 27	<i>Confussion Matrix</i> Regresi Logistik Univariat <i>Size</i> = 2	216
Lampiran 28	<i>Confussion Matrix</i> Regresi Logistik Univariat <i>Size</i> = 3	222
Lampiran 29	Perbandingan Nilai Log-Likelihood GEVR.....	228
Lampiran 30	Estimasi Parameter Model Prediksi <i>Financial Distress</i> dengan GEVR	229
Lampiran 31	<i>Confussion Matrix</i> Klasifikasi dengan Metode GEVR.....	233
Lampiran 32	Kurva ROC Klasifikasi dengan Metode GEVR.....	235
Lampiran 33	<i>Confussion Matrix</i> GEVR <i>Stepwise</i>	237
Lampiran 34	<i>Confussion Matrix</i> GEVR Univariat <i>Size</i> = 0	239
Lampiran 35	<i>Confussion Matrix</i> GEVR Univariat <i>Size</i> = 1	245

Lampiran 36	<i>Confussion Matrix</i> GEVR Univariat <i>Size = 2</i>	251
Lampiran 37	<i>Confussion Matrix</i> GEVR Univariat <i>Size = 3</i>	257
Lampiran 38	<i>Syntax</i> Uji Homogenitas Matrix Varians Kovarian	263
Lampiran 39	<i>Syntax</i> Uji Normal Multivariat	263
Lampiran 40	<i>Syntax</i> Uji Beda Rata-Rata Antar Kelompok	264
Lampiran 41	<i>Syntax</i> Partisi Data <i>Training</i> dan Data <i>Testing</i>	265
Lampiran 42	<i>Syntax</i> Analisis Diskriminan Linier	266
Lampiran 43	<i>Syntax</i> Analisis Diskriminan Kernel	269
Lampiran 44	<i>Syntax</i> Regresi Logistik Biner	272
Lampiran 45	<i>Syntax</i> GEVR	275
Lampiran 46	Surat Keterangan Data	268

(Halaman Ini Sengaja Dikosongkan)

BAB I

PENDAHULUAN

1.1 Latar Belakang

Stabilitas sistem keuangan suatu negara merupakan hal yang sangat krusial mengingat fungsi dari sistem tersebut adalah untuk menyalurkan dana dari satu pihak ke pihak lainnya. Pada dasarnya, terdapat dua elemen utama yang berkaitan dengan stabilitas sistem keuangan, yaitu stabilitas harga dan stabilitas sektor keuangan. Stabilitas sektor keuangan mencakup lembaga keuangan serta pasar keuangan yang secara keseluruhan menyokong sistem keuangan. Prasyarat suatu sistem keuangan dikatakan baik diantaranya adalah lembaga keuangan yang sehat, pasar keuangan yang stabil, serta lembaga pengaturan dan pengawasan yang kompeten (Nasution, 2003). Perbankan sebagai sektor mayoritas dalam industri keuangan memegang peranan penting dalam sistem keuangan di Indonesia.

Namun, sebagaimana yang telah diketahui, sektor perbankan di Indonesia telah mengalami pasang-surut yang diakibatkan oleh beberapa krisis keuangan baik dalam skala nasional, regional, maupun internasional. Perbankan nasional mengalami penurunan yang cukup mengkhawatirkan saat terjadi krisis ekonomi dan moneter pada tahun 1998. Pengetatan likuidasi pada awal bulan juli tahun 1997 yang disebabkan oleh terjadinya gejolak nilai tukar rupiah menurunkan kepercayaan masyarakat terhadap sistem perbankan kala itu. Depresiasi kepercayaan terhadap perbankan kian merosot pasca pencabutan izin usaha terhadap 16 bank pada bulan November 1997. Akibat yang timbul dari penurunan kepercayaan ini adalah terjadinya penarikan dana besar-besaran sehingga menyebabkan banyak bank mengalami masalah likuiditas. Keputusan likuidasi 16 bank kala itu dianggap sebagai pemicu krisis kepercayaan yang disusul dengan terpuruknya sektor perbankan. Tindakan likuidasi yang

semula dilakukan untuk mencegah semakin luasnya krisis perbankan serta besarnya risiko yang ditanggung masyarakat, nyatanya mendapat tanggapan negatif masyarakat yang menyebabkan sejumlah bank mengalami masalah likuiditas luar biasa (*mismatch*) dan mengalami saldo negatif pada gironya di Bank Indonesia (Bank Indonesia, 2008).

Kemudian pada tahun 2008, Bank Indonesia menyatakan perekonomian Indonesia menerima tekanan yang besar melalui ketidakpastian finansial global, perlambatan ekonomi dunia, serta adanya perubahan yang signifikan pada harga komoditas global. Krisis keuangan yang menghantam Amerika Serikat nyatanya turut mempengaruhi wajah perekonomian dunia. Dampak yang umumnya terjadi pada negara-negara Eropa dan Asia Pasifik adalah inflasi, turunnya nilai tukar, serta runtuhnya indeks bursa serta institusi keuangan mengalami kebangkrutan (Sudarsono, 2009).

Rentannya perbankan terganggu akan permasalahan baik secara eksternal maupun internal menjadi perhatian khusus bagi pihak terkait mengingat perbankan merupakan salah satu sektor vital bagi negara. Menurut peraturan otoritas jasa keuangan (POJK) nomor 15/POJK.03/2017 tentang penetapan status dan tindak lanjut pengawasan bank umum pasal 2 ayat 2, status pengawasan bank dibagi menjadi tiga status yaitu bank dalam pengawasan normal, bank dalam pengawasan intensif (BDPI), dan bank dalam pengawasan khusus (BDPK). Otoritas jasa keuangan (OJK) akan menetapkan suatu bank berada dalam posisi BDPI jika OJK menilai bank tersebut memiliki potensi kesulitan yang membahayakan kelangsungan usaha. Suatu bank diputuskan berada pada status BDPK jika OJK memutuskan bahwa bank tersebut mengalami kesulitan yang membahayakan kelangsungan usaha. Kriteria bank termasuk dalam status-status tersebut dapat terlihat dari rasio perbankan dan neraca dari bank tersebut. Rasio yang digunakan OJK pada POJK nomor 15.POJK.03/2017 antara lain adalah rasio Kewajiban Penyediaan Modal Minimum (KPM), rasio

modal inti (*tier 1*), rasio giro wajib minimum (GWM), serta rasio kredit bermasalah secara neto (NPL net/NPF net) (Otoritas Jasa Keuangan, 2017). Namun, masalah keuangan yang terjadi dalam dunia perbankan tidak hanya dipengaruhi oleh keadaan internal bank tersebut saja. Kondisi makro ekonomi negara turut memberi dampak bagi kondisi keuangan perbankan nasional.

Prediksi terhadap permasalahan yang mungkin terjadi di dunia perbankan menjadi salah satu solusi yang terus dikembangkan oleh komite stabilitas sistem keuangan (KSSK) yang terdiri dari Otoritas Jasa Keuangan (OJK), Bank Indonesia (BI), Lembaga Penjamin Simpanan (LPS), dan Kemenreian Keuangan Republik Indonesia. Prediksi terhadap kebangkrutan bank menjadi salah satu bentuk *early warning system* yang merupakan salah satu langkah preventif terhadap permasalahan ekonomi yang lebih luas. Kegagalan suatu bank sistemik dapat memberikan dampak terhadap penarikan dana maupun terhadap kelancaran perekonomian Indonesia. Berbagai metode untuk memprediksi kegagalan bank telah dipelajari secara berkelanjutan. Altman (1968) melakukan penelitian mengenai kebangkrutan perusahaan, dan melakukan pengelompokkan korporasi yang mengalami kebangkrutan pada kelompok 1 dan yang lainnya di kelompok 2. Namun, firma dengan aset dibawah satu juta dollar dan korporasi dengan aset yang sangat besar dikeluarkan dari sampel awal. 22 variabel yang dianggap mendukung analisis dikumpulkan dan diklasifikasikan menjadi lima kategori rasio standar yaitu *working capital/total assets*, *retained earnings/total assets*, *earning before interest and taxes/total assets*, *market value equity/book value of total debt*, dan *sales/total sales*. Kemudian Calabrese dan Osmetti (2013) melakukan penelitian mengenai kebangkrutan unit usaha kecil dan menengah (UKM) dengan metode *generalize extreme value (GEV) regression*. Variabel yang digunakan pada penelitian ini adalah rasio solvabilitas, ROE, *turnover per employee*, *cash flow*, *bank loan over*

turnover, dan *total personel cost over added value*. Simulasi Monte Carlo digunakan untuk membandingkan model dari GEV *regression* dan model logistik. Hasil dari simulasi tersebut digunakan pada data empiric dari UKM di Italia.

Zhang, Hu, Patuwo dan Indro (1997) telah melakukan penelitian terhadap prediksi kebangkrutan bank dengan metode *artificial neural network* (ANN) dengan *general framework* dan *cross-validation analysis*. Pada penelitian tersebut, didapat hasil bahwa metode *neural network* lebih baik digunakan daripada metode regresi logistik dimana *overall classification rate* dari *neural network* berada pada 77,27% hingga 84,09% sedangkan pada regresi logistik berkisar antara 75% hingga 81,82%. Pada penelitian yang dilakukan oleh Al-Shayea, El-Rafae, El-Itter (2010) meneliti prediksi kebangkrutan bank dengan metode *neural network* (NN). Berdasarkan penelitaian tersebut, didapatkan kesimpulan bahwa untuk data yang terbatas, *artificial neural network* memberikan prediksi lebih baik dalam prediksi sebagai *early warning system*. Sebagai tambahan SOM memberikan hasil lebih baik daripada *feed-forward back propagation nerwork*. Kemudian Yuniarti (2015) telah melakukan penelitian dengan judul prediksi *finansial distress* perusahaan sektor manufaktur dan industri penghasil bahan baku utama yang terdaftar di BEI menggunakan analisis distriminan, regresi logistik biner, dan *feedforward neural network*. Hasil dari penelitian tersebut adalah prediksi kondisi *finansial distress* paling baik dilakukan hanya untuk satu periode kedepan dengan *window size* yang optimal adalah satu. Menurut penelitian Yuniarti (2015) faktor yang berpengaruh dalam memprediksi kondisi *finansial distress* adalah *current ratio*, ROE, *gross profit ratio*, ROI, *total liabilitas*, dan PER. Metode terbaik yang digunakan untuk memprediksi kondisi *finansial distress* adalah *feedforward neural network* (FFNN). Nastiti (2016) melakukan penelitian mengenai estimasi risiko investasi saham pada sektor telekomunikasi dengan menggunakan *conditional value at risk* (CVaR) dan *value at risk*

(VaR) dengan pendekatan ARMA-GARCH dan *extreme value theory* (EVT). Hasil penelitian yang dilakukan Nastiti adalah estimasi VaR dengan pendekatan EVT menghasilkan nilai yang lebih besar dari estimasi VaR dengan pendekatan ARMA-GARCH sehingga diantara kedua metode estimasi VaR, metode pendekatan EVT lebih baik dibanding metode pendekatan ARMA-GARCH.

Pada penelitian ini digunakan metode untuk mengklasifikasikan suatu bank adalah analisis diskriminan, regresi logistik, dan *generalized extreme value regression*. Analisis diskriminan digunakan untuk memodelkan status bank berdasarkan rasio-rasio keuangan bank. Namun, analisis diskriminan linier memiliki beberapa asumsi yang harus dipenuhi. Jika terdapat asumsi yang tidak terpenuhi maka dapat digunakan metode lain seperti analisis diskriminan kuadratik maupun analisis diskriminan kernel. Regresi logistik yang digunakan pada penelitian ini merupakan regresi logistik biner dikarenakan variabel respon yang hanya memiliki dua kemungkinan yaitu sehat dan bermasalah yang dinotasikan dengan 0 dan 1. Namun, regresi logistik memiliki beberapa kekurangan. Salah satu kekurangan dari metode regresi logistik adalah metode ini kurang baik digunakan pada data yang *unbalance* atau dapat dikatakan sebagai kejadian langka. Kekurangan ini akan diatasi dengan metode *generalized extreme value regression*. *Generalized extreme value regression* digunakan karena variabel respon yang digunakan merupakan data berskala nominal yaitu bank sehat dan bank bermasalah. Populasi yang sangat berbeda antara kedua variabel respon dimana jumlah bank umum yang dinyatakan gagal oleh OJK hanya berjumlah dua bank selama satu dekade terakhir. Jumlah ini tentu sangat berbeda dibandingkan jumlah bank umum di Indonesia yang jumlahnya mencapai puluhan hingga saat ini.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, permasalahan yang dibahas pada penelitian ini adalah bagaimana membentuk model prediksi *financial distress* bank umum di Indonesia yang akurat. Permasalahan secara spesifik dapat dirumuskan sebagai berikut:

1. Bagaimana karakteristik rasio keuangan dari bank sehat dan bank bermasalah di Indonesia?
2. Variabel apakah yang secara signifikan berpengaruh pada kondisi keuangan bank?
3. Bagaimana model prediksi *financial distress* bank umum di Indonesia menggunakan analisis diskriminan kernel, regresi logistik, dan *generalized extreme value regression*?

1.3 Tujuan Penelitian

Berdasarkan rumusan permasalahan yang telah disusun, tujuan penelitian ini secara umum adalah untuk memperoleh model prediksi *financial distress* bank umum di Indonesia yang akurat. Secara spesifik, tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut:

1. Mendeskripsikan karakteristik rasio keuangan dari bank sehat dan bank bermasalah di Indonesia.
2. Mendeteksi variabel yang berpengaruh signifikan pada kondisi keuangan bank.
3. Memodelkan *financial distress* bank umum di Indonesia menggunakan analisis diskriminan kernel, regresi logistik, dan *generalized extreme value regression*.

1.4 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat bagi seluruh pihak diantaranya adalah sebagai berikut:

1. Menjadi *early warning system* bagi pihak-pihak yang terkait seperti pemerintah, OJK, LPS, dan pihak-pihak yang mungkin terkena imbas dari kebangkrutan bank.
2. Memberikan gambaran terkait *credit rate* sebagai bentuk manajemen risiko investasi dalam perbankan.

3. Memberikan pengetahuan mengenai metode statistika terutama metode analisis diskriminan kernel, regresi logistik, dan *generalized extreme value regression* serta penerapannya dalam bidang ekonomi.

1.5 Batasan Masalah

Batasan masalah yang digunakan dalam penelitian ini adalah data yang digunakan hanya bersal dari bank-bank umum di Indonesia sehingga analisis tidak mencakup bank syariah maupun bank perkreditan rakyat (BPR).

(Halaman ini sengaja dikosongkan)

BAB II

TINJAUAN PUSTAKA

Tinjauan pustaka akan membahas mengenai metode yang digunakan dalam penelitian ini. Metode yang dimaksud adalah analisis diskriminan kernel, regresi logistik, dan *generalized extreme value regression*. Teori-teori yang terkait juga akan dibahas pada bab ini.

2.1 Imputasi *k-Nearest Neighbor*

Imputasi dengan metode *k-Nearest Neighbor* (kNN) didasarkan pada observasi donor. Nilai yang digunakan untuk mengisi *missing value* pada data adalah agregat dari nilai k yang dianggap sebagai nilai yang bertetangga. Agregat yang dimaksud dapat berbeda-beda tergantung dari jenis variabel yang akan diatasi *missing value*-nya. Perhitungan jarak dilakukan dengan menggunakan perpanjangan dari jarak Gower. Jarak yang dimaksud melibatkan nilai rata-rata kontribusi yang terboboti pada masing-masing variabel, sehingga jarak dianggap dapat merepresentasikan variabel-variabel yang dianggap paling penting. Persamaan yang digunakan untuk menghitung jarak observasi ke- i dan observasi ke- j adalah sebagai berikut:

$$d_{i,j} = \frac{\sum_{k=1}^p w_k \delta_{i,j,k}}{\sum_{k=1}^p w_k}, \quad (2.1)$$

dengan bobot dinotasikan dengan w_k dan kontribusi variabel ke- k dinotasikan dengan $\delta_{i,j,k}$. Nilai dari $\delta_{i,j,k}$ untuk variabel yang bersifat kontinu dapat dihitung menggunakan persamaan sebagai berikut:

$$\delta_{i,j,k} = |x_{i,k} - x_{j,k}| r_k, \quad (2.2)$$

dengan $x_{i,k}$ merupakan nilai variabel ke- k dari observasi ke- i , $x_{j,k}$ merupakan nilai variabel ke- k dari observasi ke- j , dan r_k merupakan range dari variabel ke- k (Kowarik & Templ, 2016).

2.2 Analisis Diskriminan

Analisis diskriminan adalah salah satu teknik multivariat yang bertujuan untuk memisahkan observasi-observasi yang berbeda dan mengelompokkannya kembali kedalam kelompok yang baru (Johnson & Wichern, 2007). Terdapat beberapa asumsi yang harus dipenuhi dalam analisis diskriminan yaitu asumsi homogenitas dan asumsi distribusi normal multivariat. Pada analisis diskriminan linier terdapat beberapa pendekatan, salah satunya yaitu pendekatan *Fisher*. Jika $\hat{\lambda}_1, \hat{\lambda}_2, \dots, \hat{\lambda}_s > 0$ dengan $s \leq \min(g - 1, p)$ merupakan *nonzero eigenvalue* dari $\mathbf{S}_W^{-1}\mathbf{S}_B$ dan $\hat{\mathbf{e}}_1, \hat{\mathbf{e}}_2, \dots, \hat{\mathbf{e}}_s$ merupakan eigenvektor yang koresponden. Vektor dari koefisien $\hat{\mathbf{a}}$ dihitung dengan memaksimalkan rasio berikut:

$$J(\hat{\mathbf{a}}) = \frac{\hat{\mathbf{a}}' \mathbf{S}_B \hat{\mathbf{a}}}{\hat{\mathbf{a}}' \mathbf{S}_W \hat{\mathbf{a}}}, \quad (2.3)$$

dengan persamaan $\mathbf{S}_B = \sum_{i=1}^g (\bar{\mathbf{x}}_i - \bar{\mathbf{x}})(\bar{\mathbf{x}}_i - \bar{\mathbf{x}})'$ dan persamaan $\mathbf{S}_W = \sum_{i=1}^g \sum_{j=1}^{n_j} (\bar{\mathbf{x}}_{ij} - \bar{\mathbf{x}}_i)(\bar{\mathbf{x}}_{ij} - \bar{\mathbf{x}}_i)'$. Diskriminan dari sampel ke- i dapat dituliskan sebagai $\hat{\mathbf{a}}_i' \mathbf{x}$ dimana $i = 1, 2, \dots, k$.

$$\hat{\mathbf{a}}_i' \mathbf{S}_{pooled} \hat{\mathbf{a}}_k = \begin{cases} 1, & \text{jika } i = k \leq s \\ 0, & \text{jika } i \text{ lainnya} \end{cases}. \quad (2.4)$$

Apabila nilai $i = k \leq s$, maka diskriminan yang terbentuk pada masing-masing sampel tidak akan memiliki nol kovarian. Diskriminan yang terbentuk adalah $\hat{y}_i = \hat{\mathbf{a}}_i' \mathbf{x}$. Suatu pengamatan diklasifikasikan kedalam π_k jika:

$$\sum_{j=1}^r (y_j - \mu_{ky_j})^2 = \sum_{j=1}^r [\mathbf{a}'_j (\mathbf{x} - \boldsymbol{\mu}_k)^2] \leq \sum_{j=1}^r [\mathbf{a}'_j (\mathbf{x} - \boldsymbol{\mu}_i)^2] \quad (2.5)$$

untuk $i \neq k$ (Johnson & Wichern, 2007).

a. Uji Homogenitas

Salah satu asumsi yang harus dipenuhi dalam analisis diskriminan linier adalah matriks varians kovarians yang

homogen. Uji homogenitas matriks varians kovarians bertujuan untuk mendeteksi dua atau lebih kelompok data sampel dari populasi memiliki matriks varians kovarians yang homogen. Statistik uji yang digunakan dalam pengujian ini adalah statistik uji *Box's M*. Hipotesis untuk uji homogenitas adalah sebagai berikut (Johnson & Wichern, 2007):

$H_0: \Sigma_1 = \Sigma_2 = \dots = \Sigma_g = \Sigma$ (matriks varians kovarians bersifat homogen)

H_1 : minimal terdapat satu $\Sigma_i = \Sigma$ (matriks varians kovarians tidak homogen)

dimana banyak kelompok dinotasikan sebagai g . Statistik uji *Box's M* dapat dihitung melalui persamaan (2.6):

$$C = (1 - \mu)M, \quad (2.6)$$

dengan

$$u = \left[\sum_{l=1}^g \frac{1}{(n_l-1)} - \frac{1}{\sum_{l=1}^g (n_l-1)} \right] \left[\frac{2p^2-3p-1}{6(p+1)(g-1)} \right],$$

$$M = \left[\sum_{l=1}^g (n_l - 1) \right] \ln |\mathbf{S}_{pooled}| - \sum_{l=1}^g (n_l - 1) \ln |\mathbf{S}_l|,$$

$$\mathbf{S}_{pooled} = \frac{1}{\sum_{l=1}^g (n_l-1)} - \{ (n_1 - 1)\mathbf{S}_1 + \dots + (n_g - 1)\mathbf{S}_g \},$$

dengan n_l merupakan banyaknya data pada kelompok ke- l , untuk nilai $l = 1, 2, \dots, g$, \mathbf{S}_{pooled} merupakan matriks varians kovarians kelompok gabungan, p adalah jumlah variabel independen, dan \mathbf{S}_l merupakan matriks varians kovarians kelompok ke- l . Persamaan untuk mendapatkan matriks \mathbf{S}_l adalah sebagai berikut:

$$\mathbf{S}_l = \begin{bmatrix} s_{11} & s_{12} & \dots & s_{1p} \\ s_{21} & s_{22} & \dots & s_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ s_{p1} & s_{p2} & \dots & s_{pp} \end{bmatrix},$$

dengan persamaan $s_{ik} = \frac{1}{n} \sum_{j=1}^n (x_{ji} - \bar{x}_i)(x_{jk} - \bar{x}_k)$ untuk nilai $i = 1, 2, \dots, p$ dan $k = 1, 2, \dots, p$. Pada kasus $i = k$ maka

nilai $s_{ik} = s_{kk}$ menjadi $s_{kk} = \frac{1}{n} \sum_{j=1}^n (x_{ji} - \bar{x}_i)^2$. H_0 akan ditolak apabila $C > \chi_{p(p+1)(g-1)/2}^2(\alpha)$.

b. Uji Distribusi Normal Multivariat

Uji distribusi normal multivariat dilakukan dengan menggunakan metode *mardia's test on multinormality*. Uji dengan metode *mardia's test* menggunakan nilai *skewness* dan nilai *kurtosis* untuk menguji apakah suatu data berdistribusi normal multivariat. Nilai dari *skewness* dan *kurtosis* data multivariat dapat dihitung dengan persamaan sebagai berikut:

$$b_{1,p} = \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n [(\mathbf{x}_i - \bar{\mathbf{x}})' \mathbf{S}^{-1} (\mathbf{x}_j - \bar{\mathbf{x}})]^3 \quad (2.7)$$

dan

$$b_{2,p} = \frac{1}{n} \sum_{i=1}^n [(\mathbf{x}_i - \bar{\mathbf{x}})' \mathbf{S}^{-1} (\mathbf{x}_i - \bar{\mathbf{x}})]^2 \quad (2.8)$$

dengan $\mathbf{S} = \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})' / n$.

Central moment orde ketiga untuk normal multivariat adalah nol, sehingga $b_{1,p}$ akan bernilai nol ketika \mathbf{x} berdistribusi normal dengan parameter μ dan σ^2 . Jika \mathbf{x} berdistribusi normal, maka nilai $b_{2,p}$ akan menjadi $p(p+2)$. Hipotesis yang digunakan dalam pengujian ini adalah sebagai berikut (Rencher, 2002):

H_0 : Data berdistribusi normal

H_1 : Data tidak berdistribusi normal.

Statistik uji yang digunakan adalah sebagai berikut:

$$z_1 = \frac{(p+1)(n+1)(n+3)}{6[(n+1)(p+1)-6]} b_{1,p}. \quad (2.9)$$

Hipotesis nol akan ditolak jika nilai $z_1 \geq \chi_{0,05, \frac{1}{6}p(p+1)(p+2)}^2$ dan statistik uji untuk z_2 adalah sebagai berikut:

$$z_2 = \frac{b_{2,p} - p(p+2)}{\sqrt{8p(p+2)/n}} \quad (2.10)$$

nilai z_2 diharapkan tidak terlalu kecil dan tidak terlalu besar. Nilai z_2 menggambarkan bentuk puncak distribusi. Jika nilainya terlalu besar atau terlalu kecil akan menunjukkan puncak distribusi yang terlalu lancip atau terlalu landai.

c. Uji Perbedaan Rata-Rata Antar Kelompok

Setelah dilakukan pengujian terhadap asumsi homogenitas matriks varians kovarian serta pengujian asumsi normal multivariat, dilakukan pengujian perbedaan rata-rata antar kelompok menggunakan statistik uji *Wilks' lambda*. Hipotesis yang digunakan adalah sebagai berikut (Johnson & Wichern, 2007):

$$H_0: \mu_1 = \mu_2 = \dots = \mu_g$$

$$H_1: \text{minimal terdapat satu } \mu_i \neq \mu_j.$$

Statistik uji *Wilks' lambda* yang digunakan adalah sebagai berikut:

$$\Lambda^* = \frac{|W|}{|B+W|}, \quad (2.11)$$

dengan

$$\mathbf{B} = \sum_{l=1}^g n_l (\bar{\mathbf{x}}_l - \bar{\mathbf{x}})(\bar{\mathbf{x}}_l - \bar{\mathbf{x}})',$$

$$\mathbf{W} = \sum_{l=1}^g \sum_{j=1}^{n_l} (\mathbf{x}_{lj} - \bar{\mathbf{x}}_l)(\mathbf{x}_{lj} - \bar{\mathbf{x}}_l)',$$

dengan Λ^* merupakan nilai statistik uji *Wilks' lambda*, \mathbf{W} merupakan matriks *sum of square within group*, \mathbf{B} merupakan matriks *sum of square between group*, dan n_l adalah jumlah pengamatan pada kelompok ke- l . Nilai statistik uji *Wilks' lambda* dibandingkan dengan nilai-nilai berikut sesuai dengan jumlah variabel dan jumlah kelompok.

Tabel 2.1 *Distribution of Wilks' Lambda*

Jumlah Variabel	Jumlah Kelompok	Daerah Kritis
$p = 1$	$g \geq 2$	$\left(\frac{\sum_{i=1}^g n_i - g}{g - 1}\right) \left(\frac{1 - \Lambda^*}{\Lambda^*}\right) > F_{g-1, \sum_{i=1}^g n_i - g}$
$p = 2$	$g \geq 2$	$\left(\frac{\sum_{i=1}^g n_i - g - 1}{g - 1}\right) \left(\frac{1 - \sqrt{\Lambda^*}}{\sqrt{\Lambda^*}}\right) > F_{2(g-1), 2(\sum_{i=1}^g n_i - g - 1)}$
$p \geq 1$	$g = 2$	$\left(\frac{\sum_{i=1}^g n_i - p - 1}{p}\right) \left(\frac{1 - \Lambda^*}{\Lambda^*}\right) > F_{p, \sum_{i=1}^g n_i - p - 1}$
$p \geq 1$	$g = 3$	$\left(\frac{\sum_{i=1}^g n_i - p - 2}{p}\right) \left(\frac{1 - \sqrt{\Lambda^*}}{\sqrt{\Lambda^*}}\right) > F_{2p, 2(\sum_{i=1}^g n_i - p - 2)}$

2.3 Analisis Diskriminan Kernel

Salah satu metode yang dapat digunakan untuk klasifikasi pada kasus *non-linear* adalah analisis diskriminan kernel. Sama halnya dengan analisis diskriminan linier, pada analisis diskriminan kernel digunakan pendekatan *Fisher*. Data yang diasumsikan mengikuti suatu distribusi yang bukan merupakan distribusinya akan menghasilkan klasifikasi yang kurang baik. Langkah pertama dari analisis diskriminan kernel adalah memetakan data *non-linear* kedalam *feature space* \mathcal{F} . Misal Φ adalah pemetaan non-linier dari *feature space* \mathcal{F} , diskriminan linier \mathcal{F} akan didapatkan dengan memaksimumkan persamaan (2.12) (Mika, Ratsch, Jason, Scholkopf, & Muller, 1999):

$$J(\boldsymbol{\omega}) = \frac{\boldsymbol{\omega}^T S_B^\Phi \boldsymbol{\omega}}{\boldsymbol{\omega}^T S_W^\Phi \boldsymbol{\omega}}, \quad (2.12)$$

dengan $\boldsymbol{\omega} \in \mathcal{F}$ dan $S_B^\Phi = (m_1^\Phi - m_2^\Phi)(m_1^\Phi - m_2^\Phi)^T$ serta $S_W^\Phi = \sum_{i=1,2} \sum_{x \in \mathcal{X}_i} (\Phi(x) - m_i^\Phi)(\Phi(x) - m_i^\Phi)^T$ dengan persamaan $m_i^\Phi = \frac{1}{l_i} \sum_{j=1}^{l_i} \Phi(x_j^i)$.

Diskriminan kernel dengan pendekatan *Fisher* dihitung dengan memasukkan fungsi kernel kedalam persamaan (2.12) dan fungsi perluasan dari $\boldsymbol{\omega}$ pada persamaan (2.13).

$$\boldsymbol{\omega} = \sum_{i=1}^l \alpha_i \Phi(x_i), \quad (2.13)$$

Persamaan (2.7) dan persamaan m_i^Φ menghasilkan persamaan (2.8).

$$\boldsymbol{\omega}^T m_i^\Phi = \frac{1}{l_i} \sum_{j=1}^l \sum_{k=1}^{l_i} \alpha_j k(x_j, x_k^i) = \alpha^T M_i, \quad (2.14)$$

dengan $(M_i)_j = \frac{1}{l_i} \sum_{j=1}^l \sum_{k=1}^{l_i} k(x_j, x_k^i)$. Melalui persamaan (2.8) didapatkan persamaan baru dari $\boldsymbol{\omega}^T S_B^\Phi \boldsymbol{\omega}$ sebagai berikut:

$$\boldsymbol{\omega}^T S_B^\Phi \boldsymbol{\omega} = \alpha^T M \alpha, \quad (2.15)$$

dengan $M = (M_1 - M_2)(M_1 - M_2)^T$. Persamaan $\boldsymbol{\omega}^T S_W^\Phi \boldsymbol{\omega}$ juga berubah menjadi sebagai berikut:

$$\boldsymbol{\omega}^T S_W^\Phi \boldsymbol{\omega} = \alpha^T N \alpha, \quad (2.16)$$

dimana $N = \sum_{j=1,2} K_j (I - 1_{l_j}) K_j^T$. Diketahui K_j adalah matriks $l \times l_j$ dengan $(K_j)_{nm} = k(x_n, x_m^j)$, I adalah matriks identitas, dan 1_{l_j} adalah semua entri dari $1/l_j$. Persamaan analisis diskriminan kernel dengan pendekatan *Fisher* didapatkan dengan memaksimumkan persamaan (2.9):

$$J(\alpha) = \frac{\alpha^T M \alpha}{\alpha^T N \alpha}. \quad (2.17)$$

Pola baru dari \mathbf{x} akan diproyeksikan kedalam $\boldsymbol{\omega}$ dengan fungsi sebagai berikut:

$$(\boldsymbol{\omega} \cdot \Phi(x)) = \sum_{i=1}^l \alpha_i k(x_i, x). \quad (2.18)$$

2.4 Regresi Logistik

Regresi logistik merupakan metode pemodelan dengan variabel respon yang berskala kualitatif. Regresi logistik biner merupakan regresi logistik dimana variabel respon hanya memiliki dua nilai (dikotomi) yaitu sukses yang dinotasikan sebagai 1 dan gagal yang dinotasikan dengan 0. Oleh sebab itu, variabel respon dapat dikatakan mengikuti distribusi Bernoulli.

Model regresi logistik adalah GLM dengan komponen random binomial dan *logit link function*. Model regresi logistik biasa disebut dengan model logit. Kelebihan dari metode regresi logistik adalah banyaknya informasi yang didapatkan melalui hasil analisis. Salah satunya adalah *odds ratio*. Berikut adalah persamaan yang digunakan untuk menghitung nilai *odds ratio* (Johnson & Wichern, 2007):

$$\text{odds ratio} = \frac{\pi(x)}{1 - \pi(x)}, \quad (2.19)$$

dengan $\pi(x)$ merupakan probabilitas suatu bank dinyatakan mengalami *financial distress*. Probabilitas bank mengalami *financial distress* untuk bank ke- i dapat dirumuskan sebagai berikut (Hardle & Prastyo, 2014).

$$\pi(x) = P(y_i = 1|x_i) = \frac{\exp(\alpha + \beta x)}{1 + \exp(\alpha + \beta x)}, \quad (2.20)$$

dan probabilitas bank tidak mengalami *financial distress* adalah sebagai berikut:

$$P(y_i = 0|x_i) = 1 - P(y_i = 1|x_i) = \frac{1}{1 + \exp(\alpha + \beta x)}. \quad (2.21)$$

Link function yang digunakan untuk persamaan regresi logistik adalah sebagai berikut:

$$\frac{\pi(x)}{1 - \pi(x)} = \exp(\alpha + \beta x), \quad (2.22)$$

maka

$$g(x) = \ln \left(\frac{\pi(x)}{1 - \pi(x)} \right) = \alpha + \beta x, \quad (2.23)$$

dimana log dari persamaan tersebut memiliki hubungan yang linier $\log \frac{\pi(x)}{1 - \pi(x)} = \alpha + \beta x$. Oleh karena itu, *link function* yang digunakan adalah transformasi dari log persamaan yang disebut dengan logit (Agresti, 2002).

2.5 Extreme Value Theory

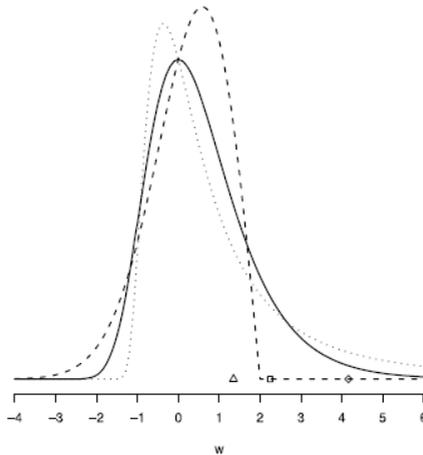
Extreme Value Theory (EVT) umumnya digunakan untuk menggambarkan kejadian yang dianggap sangat jarang terjadi sehingga dapat dikatakan sebagai kejadian langka, namun memiliki dampak yang besar (Dharmawan, 2012). Dalam bidang finansial, kejadian langka tidak dapat diremehkan karena membawa risiko besar dalam stabilitas sistem keuangan. Terdapat tiga distribusi nilai ekstrim yang merepresentasikan distribusi G adalah sebagai berikut:

$$\text{Fréchet} : G_{1,\tau}(x) = e^{(-x^{-\tau})}, x \geq 0, \text{ untuk } \tau > 0$$

$$\text{Gumbel} : G_0(x) = e^{(-e^{-x})}, x \in R$$

$$\text{Weibull} : G_{2,\tau}(x) = e^{(-|x|^{-\tau})}, x \leq 0, \text{ untuk } \tau < 0$$

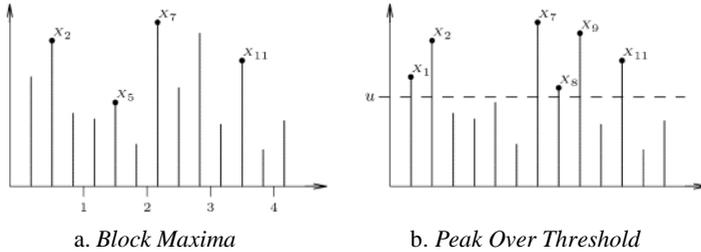
dimana τ merepresentasikan kuantil yang digunakan dalam perhitungan tingkat risiko.



Gambar 2.1 Probability Density Function dari Distribusi Weibull (*dashed*), Distribusi Gumbel (*solid*), dan Distribusi Fréchet (*dotted*)

Sumber : (Wang & Dey, 2010)

Dua pendekatan tersedia dalam EVT yaitu pendekatan *Block Maxima* (BM) dan *Peak Over Threshold* (POT).



Gambar 2.2 Skema *Block Maxima* dan *Peak Over Threshold*

Sumber: (Gilli & Kellezi, 2006)

Pendekatan *block maxima* mempertimbangkan variabel maksimum yang dibutuhkan dalam periode berturut-turut. Observasi terpilih ini merupakan kejadian ekstrim, disebut juga *block maxima*. Sedangkan pendekatan *peak over threshold* berfokus pada realisasi yang melampaui ambang batas (tinggi) yang diberikan (Gilli & Kellezi, 2006).

2.6 *Generalized Extreme Value Distribution*

Generalized Extreme Value (GEV) *distribution* pertama kali dikenalkan oleh Jenkinson. Distribusi *Generalized Extreme Value* (GEV) merupakan bagian dari distribusi probabilitas kontinu yang berkaitan erat dengan *Extreme Value Theory*. Distribusi GEV memiliki tiga parameter dengan berbagai macam metode yang dapat digunakan untuk mengestimasi paramaternya. Variabel random \mathbf{X} dapat dikatakan berdistribusi GEV jika memiliki *probability density function* (pdf) sebagai berikut:

$$f(x) = \frac{1}{\sigma} \exp[-(1 - \tau)Y - \exp(-Y)], \quad (2.24)$$

$$\text{dengan, } Y = \begin{cases} -\frac{1}{\tau} \log \left(1 - \frac{\tau(x-\mu)}{\sigma} \right); \tau \neq 0 \\ \frac{(x-\mu)}{\sigma}; \tau = 0 \end{cases}$$

dengan nilai τ merupakan parameter bentuk, μ adalah parameter lokasi, dan σ merupakan parameter skala. Berikut adalah *cumulative distribution function* (CDF) dari GEV:

$$F_X(x) = \exp \left\{ - \left[1 + \tau \left(\frac{x-\mu}{\sigma} \right) \right]^{-1/\tau} \right\}, \quad (2.25)$$

dengan $-\infty < \tau < +\infty$, $-\infty < \mu < +\infty$, $\sigma > 0$ (Calabrese & Osmetti, 2013).

2.7 Generalized Extreme Value Regression

Generalized Extreme Value Regression (GEVR) merupakan salah satu pemodelan regresi *Generalized Linear Model* (GLM) dengan variabel dependen biner. GEVR menggunakan fungsi quantile dari distribusi GEV sebagai *link function*. Metode GEVR digunakan untuk mengatasi kekurangan dari metode regresi logistik. Metode regresi logistik, yang tidak mengakomodasi peristiwa *financial distress* pada bank yang merupakan kejadian langka, cenderung *underestimate* kemungkinan *financial distress* pada bank. Probabilitas bank ke- i diklasifikasikan sebagai bank dengan *financial distress* adalah sebagai berikut (Calabrese & Osmetti, 2013):

$$\pi(\mathbf{x}_i) = \exp \left\{ - [1 + \tau(\boldsymbol{\beta}'\mathbf{x}_i)]^{-1/\tau} \right\}. \quad (2.26)$$

Link function untuk GEVR adalah sebagai berikut:

$$\frac{\{-\ln[\pi(\mathbf{x}_i)]\}^{-\tau}-1}{\tau} = \boldsymbol{\beta}'\mathbf{x}_i, \quad (2.27)$$

dengan τ merupakan parameter bentuk dan $\pi(\mathbf{x}_i)$ adalah peluang x diklasifikasikan sebagai kelompok bank bermasalah. Jika *link function* dari regresi logistik disebut dengan *logit*, maka *link function* dari GEVR disebut sebagai *gevit*. Berikut merupakan persamaan dari *gevit* (Calabrese & Guidici, 2015):

$$gevit(\pi_i) = \frac{-\ln(\pi_i)^{-\tau}-1}{\tau} = \beta_0 + \sum_{j=1}^p \beta_j x_{ij} = \eta_i. \quad (2.28)$$

2.8 Estimasi Parameter

Estimasi parameter dapat dilakukan dengan beberapa metode. Metode yang dimaksud adalah metode *Maximum Likelihood Estimation* (MLE) Metode MLE mengestimasi parameter β dengan cara memaksimalkan fungsi likelihood dan mensyaratkan bahwa data harus mengikuti distribusi tertentu.

a. Estimasi Parameter Regresi Logistik

Fungsi probabilitas pada masing-masing pengamatan, dimana x_i dan y_i diasumsikan bahwa setiap pasang pengamatan adalah independen dengan pasangan pengamatan lainnya, adalah sebagai berikut (Yuniarti, 2015):

$$f(y_i) = \pi(x_i)^{y_i}(1 - \pi(x_i))^{1-y_i}, \quad (2.29)$$

dengan,

$$\pi(x_i) = \frac{e^{(\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p)}}{1 + e^{(\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p)}}, \quad (2.30)$$

nilai y pada persamaan (2.29) adalah 0 dan 1. Fungsi likelihood berdasarkan persamaan (2.29) adalah sebagai berikut:

$$l(\beta) = \prod_{i=1}^n f(y_i) = \prod_{i=1}^n \pi(x_i)^{y_i}(1 - \pi(x_i))^{1-y_i}, \quad (2.31)$$

dengan n merupakan banyaknya observasi, x_i adalah nilai variabel independen untuk pengamatan ke- i , dan y_i merupakan variabel respon untuk pengamatan ke- i . Langkah selanjutnya adalah merubah fungsi likelihood kedalam bentuk log sebagai berikut:

$$\begin{aligned} \ln(l(\beta)) &= \ln \left[\prod_{i=1}^n \pi(x_i)^{y_i}(1 - \pi(x_i))^{1-y_i} \right] \\ &= \ln \left[\left\{ \prod_{i=1}^n (1 - \pi(x_i)) \right\} \left\{ \prod_{i=1}^n e^{\left(\ln \left(\frac{\pi(x_i)}{1 - \pi(x_i)} \right) \right)^{y_i}} \right\} \right] \\ &= \ln \left[\left\{ \prod_{i=1}^n (1 - \pi(x_i)) \right\} \left\{ e^{\sum_{i=1}^n y_i \ln \left(\frac{\pi(x_i)}{1 - \pi(x_i)} \right)} \right\} \right] \end{aligned}$$

$$\begin{aligned}
&= \ln \left[\left\{ \prod_{i=1}^n \frac{1}{1 + e^{(\sum_{j=0}^p \beta_j x_j)}} \right\} e^{\sum_{i=1}^n y_i \ln \left(e^{\sum_{j=0}^p \beta_j x_j} \right)} \right] \\
&= \ln \left[\left\{ \prod_{i=1}^n \left(1 + e^{\sum_{j=0}^p \beta_j x_j} \right)^{-1} \right\} e^{(\sum_{j=0}^p (\sum_{i=1}^n y_j x_j) \beta_j)} \right] \\
&= \sum_{j=0}^p (\sum_{i=1}^n y_j x_j) \beta_j - \sum_{i=1}^n \ln \left(1 + e^{\sum_{j=0}^p \beta_j x_j} \right)
\end{aligned}$$

Nilai estimasi untuk parameter β , didapatkan melalui turunan pertama fungsi likelihood yang kemudian disamadengankan nol. Berikut merupakan penjabaran dari penjelasan tersebut:

$$\frac{\partial L(\beta)}{\partial \beta_j} = \sum_{i=1}^n y_i x_j - \sum_{i=1}^n x_{ij} \left(\frac{e^{\sum_{j=0}^p \beta_j x_{ij}}}{1 + e^{\sum_{j=0}^p \beta_j x_{ij}}} \right) = 0,$$

sehingga,

$$\sum_{i=1}^n y_i x_j - \sum_{i=1}^n x_{ij} \hat{\pi}(x_i) = 0.$$

Hasil yang tidak *closed form* seringkali didapatkan pada estimasi parameter dengan MLE. Salah satu cara untuk menangani hal tersebut adalah dengan menggunakan iterasi numerik. Banyak metode dalam iterasi numerik yang dapat digunakan dalam mengestimasi parameter, salah satunya adalah metode *Newton Raphson*. Estimasi parameter dengan metode *Newton Raphson* melibatkan matriks Hessian dalam perhitungannya. Berikut merupakan persamaan yang digunakan untuk menghitung matriks Hessian:

$$\mathbf{u}' = \left(\frac{\partial L(\beta)}{\partial \beta_0}, \frac{\partial L(\beta)}{\partial \beta_1}, \dots, \frac{\partial L(\beta)}{\partial \beta_j} \right), \quad (2.32)$$

dengan

$$\mathbf{u}_j^{(t)} = \frac{\partial L(\beta)}{\partial \beta_j} = \sum_{i=1}^n \left(y_i - u_j^{(t)} \right) x_{ij}. \quad (2.33)$$

Matriks Hessian dapat dihitung melalui turunan kedua dari persamaan log-likelihood:

$$\mathbf{H} = \frac{\partial^2 L(\beta)}{\partial \beta_j \beta_k}. \quad (2.34)$$

Langkah-langkah yang digunakan dalam iterasi numeric *Newton Raphson* adalah sebagai berikut:

1. Melakukan estimasi parameter β dengan menggunakan metode *Ordinary Least Square* (OLS) yang menghasilkan nilai awal β^0 .
2. Melalui persamaan (2.10) dihitung nilai $\pi(x_i)^0$.
3. Nilai $\pi(x_i)^0$ yang telah diperoleh digunakan untuk menghitung matriks Hessian H^0 dan vector u^0 .
4. Melakukan iterasi hingga didapatkan nilai β yang konvergen, dengan nilai β pada iterasi ke- $(t + 1)$ adalah sebagai berikut:

$$\beta^{(t+1)} = \beta^t - (H^{(t)})^{-1} u^{(t)}$$

b. Estimasi Parameter *Generalized Extreme Value Theory*

Estimasi parameter untuk metode GEVR dilakukan dengan memaksimalkan fungsi likelihood. fungsi probabilitas yang digunakan dalam perhitungan fungsi likelihood adalah sebagai berikut:

$$f(y_i) = \pi(x_i)^{y_i} (1 - \pi(x_i))^{1-y_i}, \quad (2.35)$$

dengan

$$\pi(x_i) = \exp \left\{ -[1 + \tau(\beta' x_i)]^{-\frac{1}{\tau}} \right\}, \quad (2.36)$$

sehingga fungsi likelihood untuk metode GEVR dapat dituliskan sebagai berikut:

$$\begin{aligned} l(\beta, \tau) &= \prod_{i=1}^n f(y_i) = \prod_{i=1}^n \pi(x_i)^{y_i} (1 - \pi(x_i))^{1-y_i} \\ &= \prod_{i=1}^n \exp \left\{ -[1 + \tau(\beta' x_i)]^{-\frac{1}{\tau}} \right\}^{y_i} \left(1 - \exp \left\{ -[1 + \tau(\beta' x_i)]^{-\frac{1}{\tau}} \right\} \right)^{1-y_i} \end{aligned}$$

Berdasarkan fungsi likelihood yang didapatkan, maka fungsi dari log likelihood adalah sebagai berikut:

$$l(\boldsymbol{\beta}, \tau) = \sum_{i=1}^n \left\{ -y_i [1 + \tau(\boldsymbol{\beta}'\mathbf{x}_i)]^{-1/\tau} + (1 - y_i) \ln \left[1 - \exp[-[1 + \tau(\boldsymbol{\beta}'\mathbf{x}_i)]^{-1/\tau}] \right] \right\}$$

Invers dari persamaan tersebut merupakan CDF yang hanya berlaku pada nilai $\{\mathbf{x}_i : 1 + \tau\mathbf{x}_i > 0\}$, persamaan tersebut hanya berlaku pada $\{\mathbf{x}_i : 1 + \tau\boldsymbol{\beta}'\mathbf{x}_i > 0\}$. *Score function* didapatkan dengan melakukan *differencing* pada fungsi log-likelihood dengan parameter $\boldsymbol{\beta}$ dan τ .

$$\frac{\partial l(\boldsymbol{\beta}, \tau)}{\partial \beta_j} = - \sum_{i=1}^n x_{ij} \frac{\ln[\pi(\mathbf{x}_i)] y_i - \pi(\mathbf{x}_i)}{1 + \tau\boldsymbol{\beta}'\mathbf{x}_i - \pi(\mathbf{x}_i)}$$

dengan $j = 0, 1, \dots, k$, serta

$$\frac{\partial l(\boldsymbol{\beta}, \tau)}{\partial \tau} = \sum_{i=1}^n \left[\frac{1}{\tau^2} \ln(1 + \tau\boldsymbol{\beta}'\mathbf{x}_i) - \frac{\boldsymbol{\beta}'\mathbf{x}_i}{\tau(1 + \tau\boldsymbol{\beta}'\mathbf{x}_i)} \right] \frac{y_i - \pi(\mathbf{x}_i)}{1 - \pi(\mathbf{x}_i)} \ln[\pi(\mathbf{x}_i)]$$

Kadangkala, metode maksimum likelihood tidak memberikan hasil yang *closed form* sehingga iterasi numeric dibutuhkan dalam melakukan estimasi parameter. *Initial value* yang disarankan menurut Calabrese dan Osmetti (2013) untuk parameter adalah mendekati nol sedangkan untuk parameter dilakukan perhitungan dengan persamaan log-likelihood dari distribusi Gumbel. Peluang bank diklasifikasikan sebagai bank dengan *financial distress* berubah menjadi sebagai berikut:

$$\pi(\mathbf{x}_i) = \exp(-\exp(\boldsymbol{\beta}'\mathbf{x}_i)) \quad (2.37)$$

sehingga log likelihood dari distribusi Gumbel adalah sebagai berikut:

$$l(\boldsymbol{\beta}) = \sum_{i=1}^n \{ y_i [-\exp(\boldsymbol{\beta}'\mathbf{x}_i)] + (1 - y_i) \ln [1 - \exp[-\exp(\boldsymbol{\beta}'\mathbf{x}_i)]] \}$$

Estimasi parameter kemudian dilanjutkan dengan iterasi numerik.

2.9 Uji Signifikansi Parameter

Parameter yang memiliki pengaruh signifikan terhadap variabel respon dapat dideteksi menggunakan pengujian signifikansi parameter. Hipotesis yang digunakan pada pengujian signifikansi parameter adalah sebagai berikut:

$$H_0 : \beta_j = 0$$

$$H_1 : \beta_j \neq 0$$

dengan $j = 1, 2, \dots, p$. Sedangkan statistik uji yang digunakan dalam uji signifikansi parameter adalah sebagai berikut:

$$t_{hit} = \frac{\hat{\beta}_j}{SE(\hat{\beta}_j)}, \quad (2.37)$$

dengan $\hat{\beta}_j$ merupakan estimasi parameter β ke- j dan $\widehat{SE}(\hat{\beta}_j)$ merupakan standar error dari estimasi parameter β ke- j dimana $j = 1, 2, \dots, p$ (Saputri, 2017). Keputusan tolak H_0 diambil apabila $|t_{hitung}| > t_{\alpha/2, (n-n_p)}$.

2.10 Evaluasi Model

Dalam menentukan model terbaik dalam melakukan prediksi dilakukan evaluasi terhadap model. Perhitungan terkait ketepatan klasifikasi hasil prediksi diperlukan guna mengevaluasi model yang telah terbentuk. Evaluasi klasifikasi meliputi *accuracy*, *sensitivity*, *specificity*, dan *precision*. Data *training* dan data *testing* digunakan untuk melakukan perhitungan terhadap evaluasi klasifikasi (Han, Kamber, & Pei, 2011). Sebelum dilakukan perhitungan, terlebih dahulu dibentuk *confusion matrix* sebagai berikut (Hardle, Prastyo, & Hafner, 2014).

Tabel 2.2 *Confusion Matrix*

<i>Predicted</i> (\hat{Y})	<i>Sample</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	<i>True Positive</i>	<i>False Negative</i>
<i>Non-Default</i> (0)	<i>False Positive</i>	<i>True Negative</i>
<i>Total</i>	<i>Positive</i>	<i>Negative</i>

Berdasarkan *confusion matrix* pada tabel 2.1. Berikut merupakan persamaan untuk menghitung nilai *accuracy*.

$$Accuracy = P(\hat{Y} = Y) = \frac{True\ Positif + True\ Negatif}{Positif + Negatif} \quad (2.38)$$

Nilai akurasi dapat diperoleh melalui nilai *APER* dimana $accuracy = 1 - APER$. Berikut merupakan persamaan untuk menghitung nilai *APER*.

$$APER = P(\hat{Y} \neq Y) = \frac{False\ Positive + False\ Negative}{Positif + Negatif} \quad (2.39)$$

Selain akurasi, nilai sensitifitas juga menjadi pertimbangan dalam menentukan model terbaik. Berikut merupakan persamaan untuk menghitung nilai *sensitifity*.

$$Sensitivity = P(\hat{Y} = 1|Y = 1) = \frac{True\ Positif}{Positif} \quad (2.40)$$

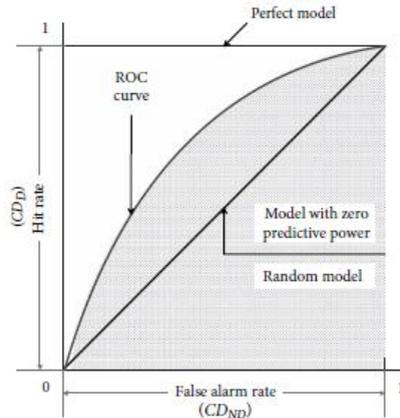
Nilai lain yang digunakan adalah nilai *specificity*. Berikut adalah persamaan untuk menghitung nilai *specificity*.

$$Specificity = (P(\hat{Y} = 0|Y = 0)) = \frac{True\ Negative}{Negative}, \quad (2.41)$$

Selanjutnya merupakan nilai *precision*. Berikut adalah persamaan yang digunakan untuk menghitung nilai presisi.

$$Precision = \frac{(\hat{Y}=1|Y=1)}{(\hat{Y}=1|Y=1) + (\hat{Y}=1|Y=0)} = \frac{True\ Positive}{True\ Positive + False\ Positive} \quad (2.42)$$

Namun, keempat nilai yang digunakan untuk membandingkan model untuk mencari model terbaik memiliki kekurangan. Nilai-nilai tersebut menjadi kurang baik digunakan pada data yang *unbalance* atau data yang tidak seimbang. Solusi yang dapat digunakan untuk mengatasi kekurangan tersebut adalah dengan menggunakan kurva ROC (*Receiver Operating Characteristic*). Kurva ROC untuk model tertentu menunjukkan *trade-off* antara *true positive rate* (TPR) dan *false positive rate* (FPR). Kurva ROC menggambarkan *trade-off* antara tingkat dimana model dapat mengidentifikasi secara tepat kasus yang positif dan secara keliru mengidentifikasi kasus negatif. Area dibawah kurva ROC adalah ukuran keakuratan model (Han, Kamber, & Pei, 2011). Berikut adalah contoh dari kurva ROC.



Gambar 2.3 Kurva ROC

Sumber: (Hardle, Prastyo, & Hafner, 2014)

Daerah dibawah kurva ROC disebut sebagai ukuran *Area Under Curve* (AUC). Ukuran AUC digunakan untuk merangkum kurva ROC kedalam suatu nilai, semakin besar nilai AUC maka model dapat dikatakan semakin baik (Witten,

Fraink, & Hall, 2011). Nilai AUC dapat dihitung berdasarkan persamaan sebagai berikut:

$$AUC = \frac{1 + TP_{rate} - FP_{rate}}{2},$$

dengan TP_{rate} adalah *sensitifity* dan $1 - FP_{rate}$ adalah rumus dari *specificity*. Sehingga persamaan AUC menjadi sebagai berikut:

$$AUC = \frac{Sensitifity + Specificity}{2}.$$

Pengklasifikasian kebaikan model berdasarkan nilai AUC menurut Gorunescu (2011) dalam Yuniarti (2015) adalah seperti pada Tabel 2.3:

Tabel 2.3 Kategori Kebaikan Model Berdasarkan AUC

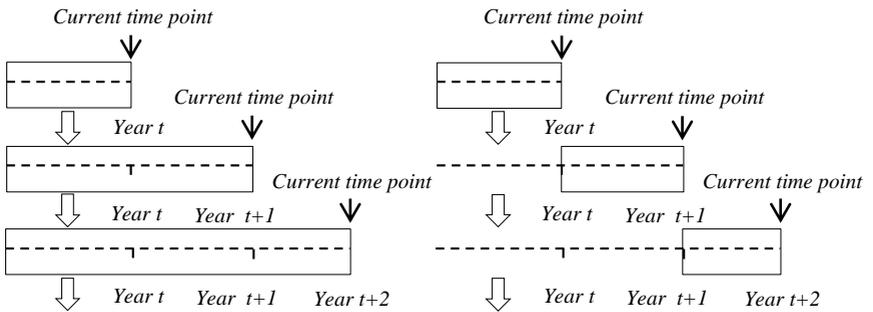
Nilai AUC	Kategori
0,9 - 1	<i>Excellent classification</i>
0,8 - 0,9	<i>Good classification</i>
0,7 - 0,8	<i>Fair classification</i>
0,6 - 0,7	<i>Poor classification</i>
< 0,6	<i>Failure</i>

2.11 Konsep Drift

Konsep *drift* secara umum didefinisikan sebagai perubahan konsep target yang disebabkan oleh perubahan *hidden context*. Perubahan yang dimaksud dapat terjadi secara langsung maupun tidak langsung. Hal ini dapat diatasi dengan penggunaan *window size* pada data *training*. Konsep ini secara khusus memperhatikan pengaruh kondisi pada waktu ke- t terhadap prediksi untuk kondisi pada waktu ke- $(t + 1)$. Misal $z = (x, y)$ terdiri atas variabel prediktor $x \in R^P$ dan variabel $y = \{0,1\}$. Data untuk setiap periodenya diumpamakan sebagai *batch*, dimana pada masing-masing *batch* terdiri dari m sampel (Klinkenberg, 2013).

$$Z_{(1,1)}, \dots, Z_{(1,m)}, Z_{(2,1)}, \dots, Z_{(2,m)}, \dots, Z_{(t,1)}, \dots, Z_{(t,m)}, Z_{(t+1,1)}, \dots, Z_{(t+1,m)}$$

dimana z_{ij} merupakan sampel ke- j pada batch ke- i . Masing-masing *batch* bersifat independen, identic dan mengikuti distribusi $Pr_i(x, y)$. Jenis *time window* yang digunakan dalam konsep *drift* diantaranya yaitu *full memory time window* dan *no memory time window*. Berikut merupakan gambaran dari jenis *time window*.



a. *full memory time window*

b. *no memory time window*

Gambar 2.4 Skema *Full Memory Time Window* dan *No Memory Time Window*

Metode *full memory window size* mempertimbangkan data pada waktu sebelumnya untuk memprediksi kondisi pada waktu setelahnya. Dengan kata lain, pada metode *full memory window size* melibatkan data baru dan data sebelumnya. Kelemahan yang dimiliki oleh model ini adalah kurangnya kemampuan model untuk beradaptasi dengan kondisi baru. Hal ini disebabkan oleh model yang masih mengandung konsep kondisi sebelumnya. Di sisi lain, metode *no memory window size* hanya mengasumsikan bahwa kondisi sebelumnya tidak memiliki hubungan dengan kondisi saat ini. Kelemahan dari metode ini adalah kurangnya generalisasi untuk jumlah data yang kecil untuk data *training* ketika model harus stabil.

2.12 Laporan Keuangan Bank

Laporan keuangan sebagaimana diatur dalam Pernyataan Standar Akuntansi Keuangan (PSAK) No. 01 paragraf 7 revisi 2009 adalah suatu penyajian terstruktur dari posisi keuangan dan kinerja keuangan suatu entitas yang menunjukkan hasil pertanggungjawaban manajemen atas penggunaan sumberdaya yang dipercayakan kepada mereka. PSAK No. 31 tentang Akuntansi Perbankan mengatur mengenai komponen yang harus tertera pada laporan keuangan bank. Komponen yang dimaksud antara lain neraca, laporan laba rugi, laporan arus kas, laporan perubahan ekuitas, serta catatan atas laporan keuangan. Menurut Mulyaningrum (2008), sesuai dengan *statement of financial accounting no. 1* tujuan dari pelaporan keuangan adalah untuk menyediakan informasi yang bermanfaat bagi pihak-pihak terkait seperti investor, kreditur, dan pemakai lainnya.

2.13 Rasio Keuangan Bank

Rasio keuangan adalah suatu ukuran mengenai perbandingan antara jumlah-jumlah yang terdapat pada laporan keuangan dengan menggunakan formula-formula yang dianggap dapat menggambarkan keadaan dari bank tersebut (Fahmi, 2016). Menurut lampiran Surat Edaran Bank Indonesia (SEBI) Nomor 3/30/DPNP tanggal 14 Desember 2001.

a. Rasio Likuiditas Bank

Rasio likuiditas bank berisi informasi mengenai kemampuan bank dalam memenuhi kewajiban yang akan jatuh tempo. Rasio kredit terhadap dana pihak ketiga atau *loan to deposit ratio* (LDR) termasuk dalam rasio likuiditas bank. Berikut merupakan persamaan yang digunakan dalam perhitungan nilai rasio LDR:

$$\text{LDR} = \frac{\text{Kredit}}{\text{Dana Pihak Ketiga}} \cdot \quad (2.44)$$

b. Rasio Rentabilitas Bank

Rasio rentabilitas bank berisi informasi mengenai kemampuan bank dalam menghasilkan keuntungan melalui operasi usaha. Rasio *return on assets* (ROA) merupakan salah satu rasio yang termasuk rasio rentabilitas. Berikut adalah persamaan untuk menghitung rasio ROA:

$$\text{ROA} = \frac{\text{Laba Sebelum Pajak}}{\text{Rata-Rata Total Aset}} \quad (2.45)$$

Rasio lainnya yang termasuk dalam rasio rentabilitas adalah rasio *return on equity* (ROE). Berikut merupakan persamaan yang digunakan untuk menghitung nilai ROE:

$$\text{ROE} = \frac{\text{Laba Setelah Pajak}}{\text{Rata-Rata Equity}} \quad (2.46)$$

Net interest margin (NIM) atau rasio pendapatan bunga bersih adalah rasio keuangan bank yang juga termasuk dalam rasio rentabilitas bank. Persamaan untuk mendapatkan nilai NIM adalah sebagai berikut:

$$\text{NIM} = \frac{\text{Pendapatan Bunga Bersih}}{\text{Rata-Rata Aktiva Produktif}} \quad (2.47)$$

Rasio terakhir yang juga merupakan rasio rentabilitas bank ialah rasio beban operasi terhadap pendapatan operasi (BOPO). Berikut merupakan persamaan untuk menghitung nilai rasio BOPO:

$$\text{BOPO} = \frac{\text{Total Beban Operasional}}{\text{Total Pendapatan Operasional}} \quad (2.48)$$

c. Rasio Aktiva Produktif

Rasio risiko usaha bank bertujuan untuk mengukur risiko bank dalam menjalankan usahanya. Rasio-rasio yang termasuk dalam rasio risiko usaha bank antara lain adalah rasio aktiva produktif bermasalah, rasio kredit bermasalah terhadap total kredit atau *non-performing loan* (NPL), rasio penyisihan penghapusan aktiva produktif (PPAP) terhadap total aktiva produktif, serta pemenuhan PPAP. Berikut merupakan

persamaan untuk menghitung nilai rasio aktiva produktif bermasalah:

$$\frac{\text{Aktiva Produktif Bermasalah}}{\text{Total Aktiva Produktif}} . \quad (2.49)$$

Persamaan yang digunakan untuk melakukan perhitungan nilai rasio NPL adalah sebagai berikut:

$$\text{NPL} = \frac{\text{Kredit Bermasalah}}{\text{Total Kredit}} . \quad (2.50)$$

Sedangkan persamaan untuk menghitung nilai rasio PPAP terhadap total aktiva adalah sebagai berikut:

$$\text{PPAP Terhadap Aktiva Produktif} = \frac{\text{PPAP yang Telah Dibentuk}}{\text{Total Aktiva Produktif}}$$

Rasio lainnya yaitu rasio pemenuhan PPAP didapatkan melalui persamaan sebagai berikut:

$$\text{Pemenuhan PPAP} = \frac{\text{PPAP yang Telah Dibentuk}}{\text{PPAP yang Wajib Dibentuk}} . \quad (2.51)$$

d. Rasio Pemodal Bank

Rasio pemodal atau yang sering disebut dengan rasio solvabilitas menginformasikan terkait kemampuan pemodal bank dalam mendukung kegiatan bank yang akan dilakukan dan mampu menyerap yang tidak dapat dihindarkan. Rasio yang termasuk kedalam kategori ini adalah rasio kewajiban penyediaan modal minimum (KPMM) atau biasa disebut dengan *capital adequacy ratio* (CAR) serta aktiva tetap terhadap modal (ATTM). Berikut adalah persamaan untuk rasio KPMM atau CAR dan rasio ATTM:

$$\text{CAR} = \frac{\text{Modal}}{\text{Aktiva Tertimbang Menurut Risiko (ATMR)}} \quad (2.51)$$

$$\text{ATTM} = \frac{\text{Aktiva Tetap dan Inventaris}}{\text{Modal}} . \quad (2.52)$$

e. **Rasio Kepatuhan**

Sedangkan rasio kepatuhan terdiri atas persentase pelanggaran BMPK, persentase pelampauan BMPK, GWM rupiah, serta persentase posisi devisa neto (PDN). Perhitungan pelanggaran dan pelampauan BMPK dilakukan sesuai dengan BMPK yang berlaku. Perhitungan persentase GWM pada posisi laporan yang dilakukan sesuai dengan GWM yang berlaku.

2.14 Kondisi Makroekonomi

Analisis mengenai penentuan tingkat kegiatan yang dicapai suatu perekonomian merupakan bagian yang penting dari analisis makroekonomi. Makroekonomi membahas isu-isu penting yang dihadapi oleh perekonomian negara. Salah satu aspek yang membedakan antara makroekonomi dan mikroekonomi adalah corak dari analisis yang dibuat. Mikroekonomi bersifat meliputi bagian-bagian kecil dari keseluruhan ekonomi dimana makroekonomi menganalisis kegiatan-kegiatan keseluruhan dan perubahan keseluruhan kegiatan ekonomi secara keseluruhan. Masalah utama dalam bidang makroekonomi diantaranya adalah pertumbuhan ekonomi. Pertumbuhan ekonomi dapat didefinisikan sebagai perkembangan kegiatan dalam perekonomian yang menyebabkan barang dan jasa yang diproduksi dalam masyarakat bertambah. Kemudian masalah makroekonomi lainnya yang sering dialami adalah inflasi. Inflasi dapat diartikan sebagai suatu proses kenaikan harga barang yang berlaku dalam suatu perekonomian. Banyak hal yang menjadi faktor penyebab terjadinya inflasi antara lain adalah tingkat pengeluaran agregat yang melebihi kemampuan perusahaan untuk menghasilkan barang/jasa, pekerja menuntut kenaikan upah, dan penyebab lainnya (Sukirno, 2013).

2.15 *Financial Distress*

Lukvirman (2009) dalam Rahmaniah (2015) *financial distress* adalah kesulitan keuangan yang terjadi sebelum kebangkrutan benar-benar terjadi. Sedangkan plat dan plat

(2002) dalam Rahmaniah (2015) mendefinisikan *financial distress* sebagai tahap penurunan kondisi keuangan yang terjadi sebelum terjadinya kebangkrutan atau likuidasi. Menurut OJK, status sebelum suatu bank dinyatakan bangkrutan dan harus dicabut izin usahanya. Ketika bank mulai mengalami permasalahan keuangan maka OJK akan mengubah status bank dari bank dalam pengawasan normal menjadi bank dalam pengawasan intensif (BDPI). Bank dinyatakan berada dalam pengawasan intensif menurut POJK Nomor 15/POJK.03/2017 tentang penetapan status dan tindak lanjut pengawasan bank umum, jika:

- a. Rasio Kewajiban Penyediaan Modal Minimum (KPMM) sama dengan atau lebih besar dari 8% (delapan persen) namun kurang dari rasio KPMM sesuai profil risiko Bank yang wajib dipenuhi oleh Bank
- b. Rasio modal inti (*tier 1*) kurang dari persentase tertentu yang ditetapkan oleh OJK
- c. Rasio GWM dalam rupiah sama dengan atau lebih besar dari rasio yang ditetapkan untuk GWM dalam rupiah yang wajib dipenuhi oleh Bank, namun berdasarkan penilaian OJK Bank memiliki permasalahan likuiditas mendasar
- d. Rasio kredit bermasalah secara neto (*Non-Performing Loan/NPL net*) atau rasio pembiayaan bermasalah secara neto (*Non-Performing Financing/NPF net*) lebih dari 5% (lima persen) dari total kredit atau total pembiayaan
- e. Ringkat kesehatan Bank dengan peringkat komposit 4 (empat) atau peringkat komposit 5 (lima); dan/atau
- f. Tingkat kesehatan Bank dengan peringkat komposit 3 (tiga) dan tata kelola dengan peringkat faktor tata kelola 4 (empat) atau peringkat faktor tata kelola 5 (lima).

Status BPDI yang ditetapkan oleh OJK memiliki jangka waktu selama satu tahun dan OJK berhak memperpanjang waktu pengawasan intensif paling banyak satu kali jika bank memenuhi kriteria yang ditetapkan oleh OJK. Jika kondisi keuangan bank terus menurun dan tidak menunjukkan adanya

perbaikan kondisi keuangan, maka OJK akan meningkatkan status bank dari BDPI menjadi bank dalam pengawasan khusus (BDPK). Suatu bank akan digolongkan kedalam kelompok BDPK jika:

- a. Rasio KPMM kurang dari 8% (delapan persen); dan/atau
- b. Rasio GWM dalam rupiah kurang dari rasio yang ditetapkan untuk GWM dalam rupiah yang wajib dipenuhi oleh Bank, dan berdasarkan penilaian OJK:
 1. Bank mengalami permasalahan likuiditas mendasar; atau
 2. Bank mengalami perkembangan likuiditas yang memburuk dalam waktu singkat.

BAB III

METODOLOGI PENELITIAN

3.1 Sumber Data

Sumber data yang digunakan pada penelitian ini adalah data sekunder yang didapatkan dari laporan publikasi OJK yang didapat diunduh melalui www.ojk.go.id dan laporan tahunan Bank Indonesia yang dapat diakses melalui www.bi.go.id. Data yang digunakan adalah data rasio keuangan bank umum di Indonesia dan data inflasi serta data pertumbuhan ekonomi Indonesia tahun 2004 sampai 2008.

3.2 Variabel Penelitian

Variabel penelitian yang digunakan pada penelitian ini adalah data rasio perbankan, data inflasi tahunan, dan data pertumbuhan ekonomi Indonesia. Tabel 3.1 menunjukkan rincian dari variabel penelitian yang digunakan.

Tabel 3.1 Variabel Penelitian

Variabel	Deskripsi	Keterangan
Y	Status Bank	1: Bank yang mengalami <i>financial distress</i> 0: Bank sehat
X_1	LDR	<i>Loan to Deposit Ratio</i>
X_2	ROA	<i>Return on Asset</i>
X_3	ROE	<i>Return on Equity</i>
X_4	NIM	<i>Net Interest Margin</i>
X_5	BOPO	Beban Operasi terhadap Pendapatan Operasional
X_6	Aktiva Produktif Bermasalah	Aktiva Produktif Bermasalah per Aktiva Produktif
X_7	NPL	<i>Non-Performing Loan</i>
X_8	PPAP Terhadap Aktiva Produktif	-
X_9	Pemenuhan PPAP	-
X_{10}	CAR	<i>Capital Adequacy Ratio</i>
X_{11}	ATTM	Aktiva Tetap Terhadap Modal
M_1	Inflasi	-
M_2	Pertumbuhan Ekonomi	-

3.3 Struktur Data

Struktur data dari variabel-variabel yang tercantum pada Tabel 3.1 terangkum dalam Tabel 3.2.

Tabel 3.2 Struktur Data

Bank	$Y_{i,t}$	$X_{1i,t}$	$X_{2i,t}$...	$X_{11i,t}$	$M_{1,t}$	$M_{2,t}$
Bank 1	$Y_{1,2004}$	$X_{11,2004}$	$X_{21,2004}$...	$X_{81,2004}$	$M_{1,2004}$	$M_{2,2004}$
...
Bank 1	$Y_{1,2008}$	$X_{11,2008}$	$X_{21,2008}$...	$X_{81,2008}$	$M_{1,2008}$	$M_{2,2008}$
Bank 2	$Y_{2,2004}$	$X_{12,2004}$	$X_{22,2004}$...	$X_{82,2004}$	$M_{1,2004}$	$M_{2,2004}$
...
Bank 2	$Y_{2,2008}$	$X_{12,2008}$	$X_{22,2008}$...	$X_{82,2008}$	$M_{1,2008}$	$M_{2,2008}$
Bank i	$Y_{i,2004}$	$X_{1i,2004}$	$X_{2i,2004}$...	$X_{8i,2004}$	$M_{1,2004}$	$M_{2,2004}$
...
Bank i	$Y_{i,2008}$	$X_{1i,2008}$	$X_{2i,2008}$...	$X_{8i,2008}$	$M_{1,2008}$	$M_{2,2008}$
Bank n	$Y_{n,2004}$	$X_{1n,2004}$	$X_{2n,2004}$...	$X_{8n,2004}$	$M_{1,2004}$	$M_{2,2004}$
...
Bank n	$Y_{n,2008}$	$X_{1n,2008}$	$X_{2n,2008}$...	$X_{8n,2008}$	$M_{1,2008}$	$M_{2,2008}$

3.4 Langkah Analisis

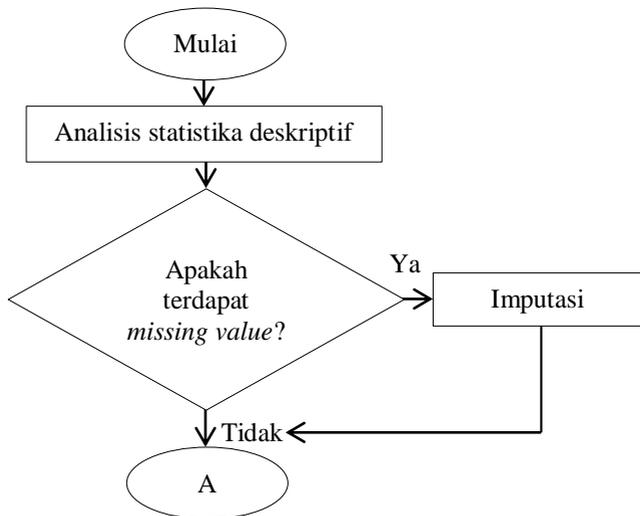
Tujuan penelitian yang telah dirumuskan akan dapat dicapai dengan langkah-langkah analisis sebagai berikut:

1. Melakukan analisis statistika deskriptif terhadap data keuangan dari bank umum baik bank sehat maupun bank gagal.
 - a. Melakukan pemeriksaan terhadap *missing value* pada data rasio keuangan bank umum di Indonesia serta melakukan imputasi data untuk *missing value* dengan metode *k Nearest Neighbor* (kNN).
 - b. Melakukan analisis statistika deskriptif pada data rasio keuangan yang meliputi nilai *mean*, median, varians, koefisien variasi.
2. Memodelkan prediksi *financial distress* bank umum di Indonesia dengan menggunakan analisis diskriminan.

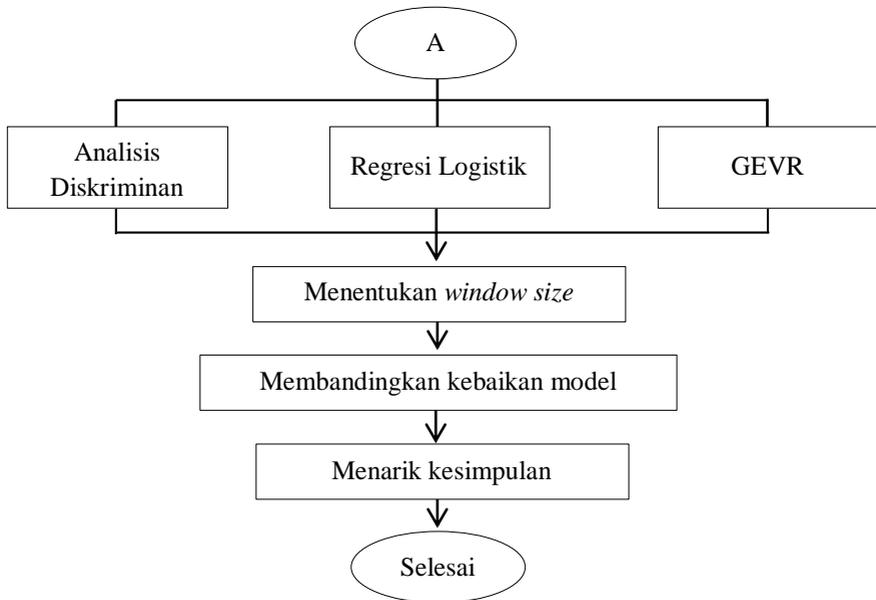
- a. Membagi data kedalam data *training* dan data *testing* dengan perbandingan data *training* dan data *testing* berturut-turut adalah 80% dan 20%.
 - b. Melakukan uji asumsi yang meliputi uji asumsi homogenitas, uji asumsi multivariat normal, dan uji beda rata-rata antar kelompok.
 - c. Jika seluruh asumsi dipenuhi, maka *financial distress* diklasifikasikan menggunakan analisis diskriminan linier. Jika asumsi homogenitas tidak terpenuhi maka digunakan analisis diskriminan kuadratik. Jika seluruh asumsi tidak dipenuhi, maka digunakan analisis diskriminan kernel dengan pendekatan *Fisher*.
 - d. Membuat *confussion matrix* hasil klasifikasi data *training* dan data *testing*.
 - e. Melakukan perhitungan nilai AUC hasil klasifikasi.
3. Memodelkan prediksi *financial distress* bank umum di Indonesia dengan menggunakan regresi logistik.
 - a. Membagi data kedalam data *training* dan data *testing* dengan perbandingan data *training* dan data *testing* berturut-turut adalah 80% dan 20%.
 - b. Melakukan perhitungan terhadap fungsi likelihood.
 - c. Melakukan estimasi parameter menggunakan metode *maximum likelihood*.
 - d. Melakukan uji signifikansi parameter.
 - e. Melakukan perhitungan *odds ratio*.
 - f. Membuat *confussion matrix* hasil klasifikasi data *training* dan data *testing*.
 - g. Melakukan perhitungan nilai AUC hasil klasifikasi.
 4. Memodelkan prediksi *financial distress* bank umum di Indonesia dengan menggunakan *generalized extreme value regression*.
 - a. Membagi data kedalam data *training* dan data *testing* dengan perbandingan data *training* dan data *testing* berturut-turut adalah 80% dan 20%.
 - b. Melakukan perhitungan terhadap fungsi likelihood.

- c. Melakukan estimasi parameter dengan metode menggunakan metode *maximum likelihood estimation* dan dilanjutkan dengan estimasi parameter secara numeric jika tidak didapatkan bentuk yang *closed form*.
 - d. Melakukan uji signifikansi parameter.
 - e. Memuat *confussion matrix* dari hasil klasifikasi data *training* dan data *testing*.
 - f. Melakukan perhitungan AUC dari hasil klasifikasi
5. Menentukan *window size* optimal untuk memprediksi *financial distress* dengan pendekatan *full memory window size*.
 6. Melakukan perbandingan kebaikan model dari ketiga metode yang digunakan.
 7. Menentukan metode terbaik untuk memprediksi *financial distress* bank umum di Indonesia.

Langkah analisis yang telah diuraikan dapat digambarkan kedalam diagram alir pada Gambar 3.1.

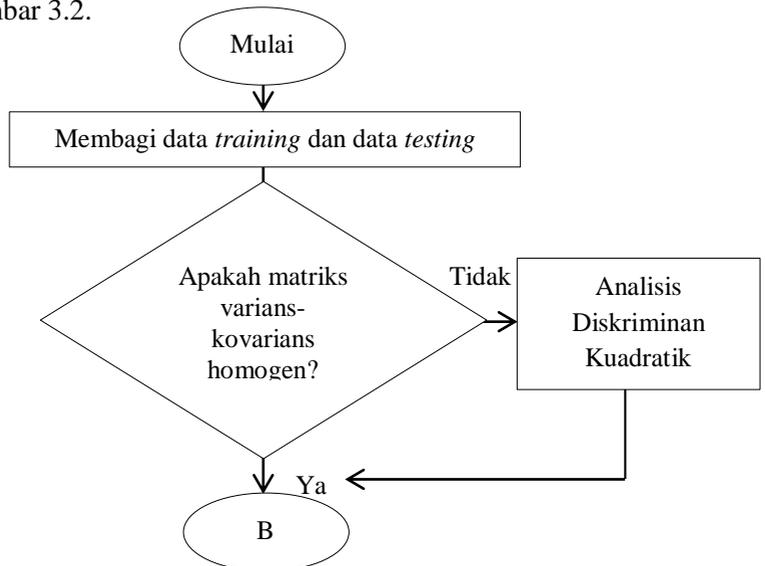


Gambar 3.1 Diagram Alir

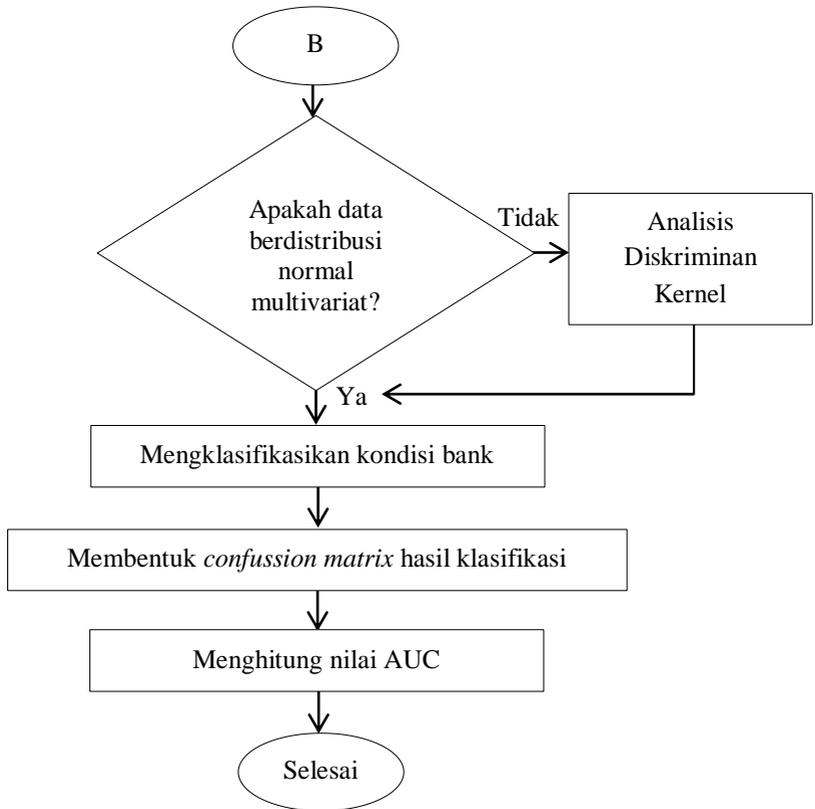


Gambar 3.1 Diagram Alir (Lanjutan)

Diagram alir untuk proses analisis diskriminan digambarkan pada Gambar 3.2.

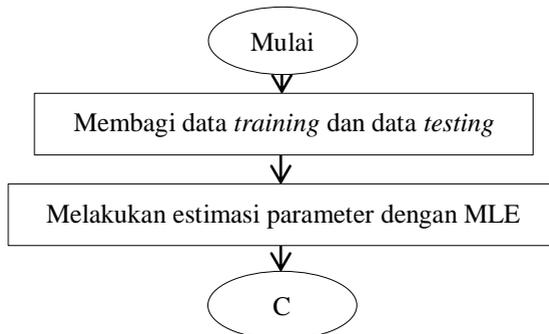


Gambar 3.2 Diagram Alir Analisis Diskriminan

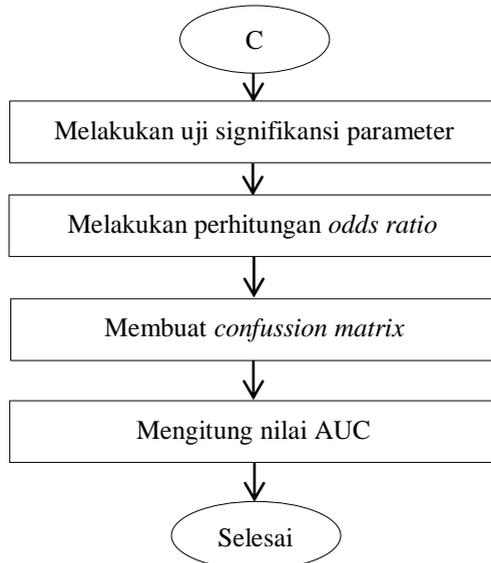


Gambar 3.2 Diagram Alir Analisis Diskriminan (Lanjutan)

Diagram alir untuk proses klasifikasi dengan metode regresi logistik digambarkan pada Gambar 3.3.

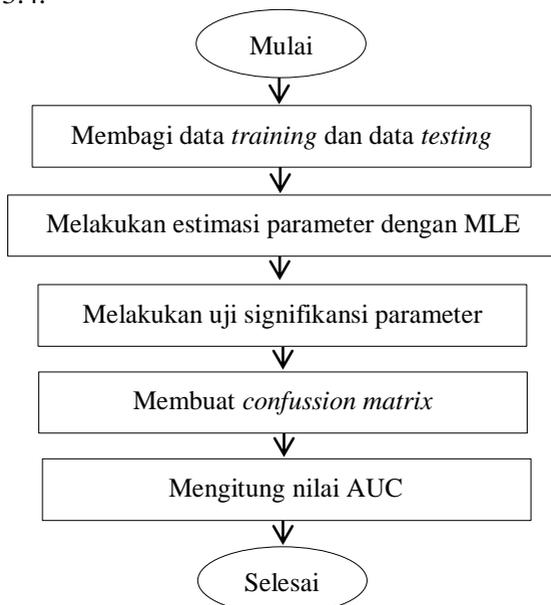


Gambar 3.3 Diagram Alir Regresi Logistik



Gambar 3.3 Diagram Alir Regresi Logistik (Lanjutan)

Diagram alir untuk proses klasifikasi dengan metode *generalized extreme value regression* digambarkan pada Gambar 3.4.



Gambar 3.4 Diagram Alir *Generalized Extreme Value Regression*

(Halaman ini sengaja dikosongkan)

BAB IV

ANALISIS DAN PEMBAHASAN

Analisis dan pembahasan yang akan diuraikan pada bab ini mencakup hasil klasifikasi bank umum di Indonesia dengan menggunakan tiga metode klasifikasi yang berbeda. Metode yang pertama adalah metode analisis diskriminan. Metode kedua yang digunakan adalah metode regresi logistik biner. Metode yang terakhir adalah metode GEVR. Klasifikasi yang dihasilkan dari ketiga metode ini akan dibandingkan untuk memilih metode yang dianggap terbaik untuk memprediksi kondisi *financial distress* bank umum di Indonesia. Ketepatan klasifikasi akan diukur dengan nilai akurasi dan AUC.

4.1 Imputasi *Missing Value* Pada Data Rasio Perbankan dan Kondisi Makroekonomi Indonesia

Data rasio keuangan perbankan dari tahun 2004 hingga tahun 2008 memiliki beberapa *missing value*. Diketahui rincian dari *missing value* setiap variabel dirangkum pada Tabel 4.1.

Tabel 4.1 Jumlah *Missing Value* Data

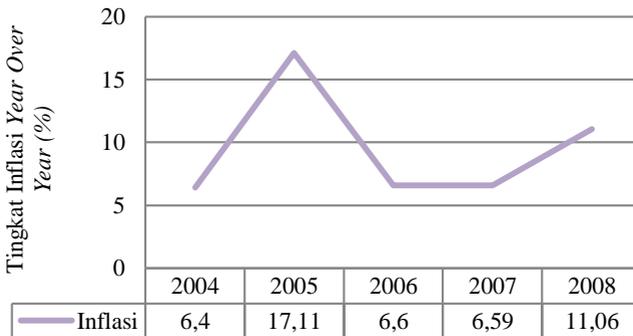
Variabel	Jumlah <i>missing</i>
LDR	0
ROA	0
ROE	0
NIM	0
BOPO	0
Aktiva Produktif Bermasalah	2
NPL	4
PPAP Terhadap Aktiva Produktif	1
Pemenuhan PPAP	0
CAR	1
ATTM	2
Inflasi	0
Pertumbuhan Ekonomi	0
Total	10

Hasil pemeriksaan menunjukkan bahwa data mengandung 10 *missing value* yang berada pada variabel aktiva produktif

bermasalah, NPL, PPAP terhadap aktiva produktif, CAR, dan ATTM. Metode imputasi yang digunakan adalah metode kNN dengan nilai k yang digunakan adalah sebesar 100. *Missing value* pada data diisi dengan nilai dari observasi yang paling menyerupai observasi dengan data yang hilang. Nilai tersebut dicari melalui 100 observasi yang berada paling dekat dengan observasi yang mengandung *missing value*.

4.2 Karakteristik Rasio Perbankan dan Kondisi Makroekonomi Indonesia

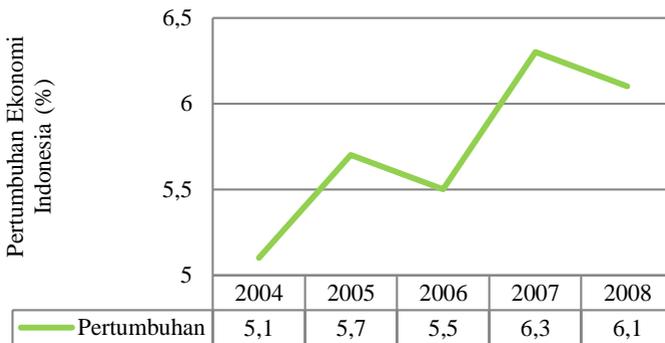
Kondisi perbankan dipengaruhi oleh faktor internal dan faktor eksternal. Faktor internal biasanya digambarkan oleh rasio-rasio keuangan yang tercantum pada laporan keuangan perbankan. Faktor eksternal dapat digambarkan dengan kondisi ekonomi nasional secara keseluruhan. Pada penelitian ini digunakan data inflasi *year over year* (YoY) dan pertumbuhan ekonomi Indonesia dari tahun 2004 hingga 2008. Gambar 4.1 mengilustrasikan pergerakan tingkat inflasi Indonesia dari tahun 2004 hingga 2008.



Gambar 4.1 Tingkat Inflasi YoY Indonesia Tahun 2004-2008

Inflasi pada tahun 2005 mengalami kenaikan yang sangat besar dibanding tahun 2004 yaitu naik dari angka 6,4% hingga 17,11%. Kenaikan inflasi juga terjadi pada tahun 2008 dimana inflasi naik dari 6,59% menjadi 11,06%. Menurut Bank Indonesia, kenaikan inflasi pada tahun 2005 dan 2008

disebabkan oleh adanya *shock* yang terjadi pada tahun tersebut. Kejadian yang dimaksud adalah adanya kenaikan harga bahan bakar minyak sehingga menyebabkan terjadinya lonjakan inflasi pada 2005 dan 2008. Selain tingkat inflasi, faktor makroekonomi lain yang digunakan adalah pertumbuhan ekonomi. Gambar 4.2 menggambarkan fluktuasi pertumbuhan ekonomi nasional Indonesia dari tahun 2004 hingga 2008.



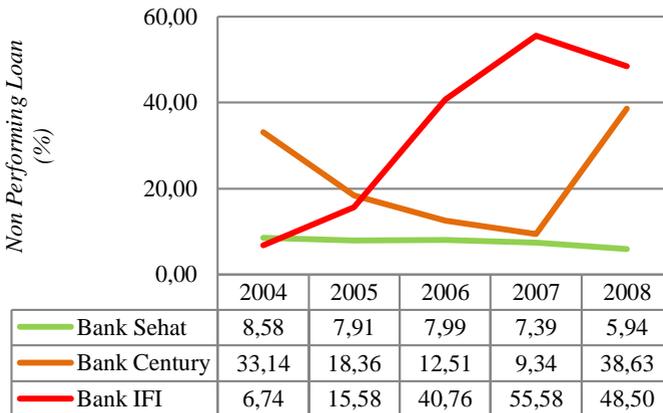
Gambar 4.2 Pertumbuhan Ekonomi Indonesia Tahun 2004-2008

Berbeda dengan inflasi yang menggambarkan kondisi perekonomian tahun 2005 yang memburuk, pertumbuhan ekonomi Indonesia tahun 2005 menunjukkan perkembangan yang baik. Perekonomian Indonesia tumbuh dari angka 5,1% menjadi 5,7% pada tahun 2005. Namun, pada tahun 2008, perekonomian Indonesia terlihat melemah. Hal ini ditunjukkan dengan naiknya tingkat inflasi dan turunnya pertumbuhan ekonomi Indonesia. Menurut Bank Indonesia dalam laporan tahunannya, perekonomian Indonesia mengalami sedikit gangguan yang disebabkan oleh terjadi krisis ekonomi global pada tahun 2008.

Faktor eksternal menggambarkan kondisi ekonomi nasional yang diindikasikan memiliki pengaruh terhadap kondisi perbankan. Faktor internal dapat digambarkan melalui rasio-rasio keuangan perbankan. Penelitian ini membagi bank kedalam dua kelompok yaitu kelompok bank sehat dan

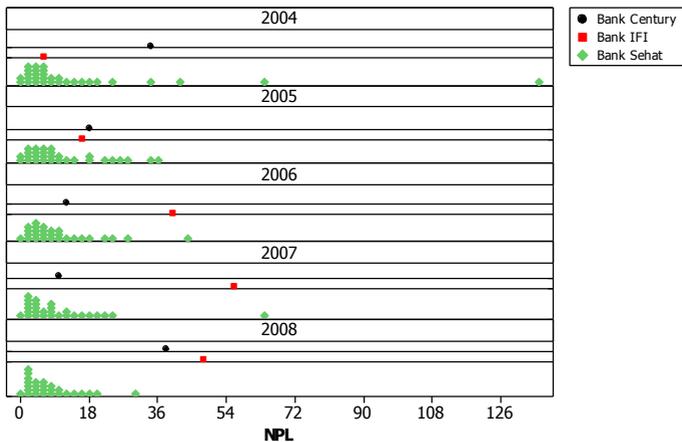
kelompok bank yang mengalami *financial distress*. Selama satu dekade terakhir, LPS telah melikuidasi dua bank umum. Jumlah ini hanya sekitar 2 dari jumlah keseluruhan bank umum yang ada di Indonesia pada tahun 2004 hingga tahun 2008 yakni sejumlah 110 bank umum.

Rasio keuangan yang digunakan dalam penelitian ini adalah LDR, ROA, ROE, NIM, BOPO, aktiva produktif bermasalah, NPL, PPAP terhadap aktiva produktif, pemenuhan PPAP, CAR, dan ATTM. Kesebelas rasio keuangan ini digunakan berdasarkan Surat Edaran Bank Indonesia (SEBI) Nomor 3/30/DPNP. Rasio-rasio keuangan yang menjadi perhatian khusus bagi OJK dalam menetapkan status bank tersebut sehat atau tidak sesuai dengan POJK Nomor 15/POJK.03/2017 adalah CAR dan NPL. Perbedaan rasio-rasio keuangan antara bank sehat dan bank yang memiliki kondisi *financial distress* dilakukan dengan membandingkan rata-rata nilai rasio keuangan bank sehat dengan nilai rasio keuangan bank dengan kondisi *financial distress*. Gambar 4.3 menggambarkan perbedaan dari rata-rata rasio keuangan NPL dari bank sehat dan bank dengan kondisi *financial distress*.



Gambar 4.3 Rata-Rata Prosentase NPL Bank Sehat dan Prosentasi NPL Bank dengan *Financial Distress*

Kondisi bank IFI terlihat mulai memburuk sejak tahun 2005 dimana NPL dari bank IFI naik dari angka 6,74% menjadi 15,58% dan terus memburuk hingga tahun 2007. Penurunan nilai NPL bank IFI terjadi pada tahun 2008, namun hal tersebut tidak cukup untuk mengembalikan kondisi keuangan bank IFI. Hal ini berbeda dengan kondisi Bank Century. NPL Bank Century yang cukup tinggi pada tahun 2004 sempat membaik hingga tahun 2007. Namun, pada tahun 2008, NPL Bank Century mengalami kenaikan yang signifikan dan menyebabkan Bank Century dilikuidasi pada tahun 2008. Nilai NPL yang tinggi mengindikasikan bahwa kredit macet dalam bank juga tinggi. Semakin tinggi nilai NPL maka semakin buruk kualitas kredit bank tersebut. Gambar 4.4 menunjukkan *dot plot* dari variabel NPL pada tahun 2004 hingga tahun 2008.

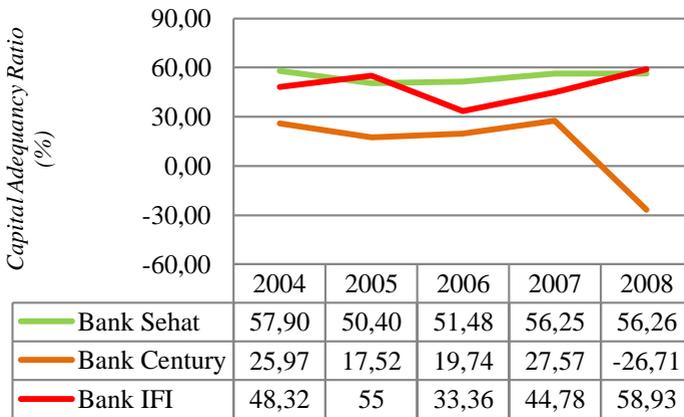


Gambar 4.4 *Dot Plot* NPL Bank Umum Tahun 2004-2008

Dot plot pada Gambar 4.4 menunjukkan adanya *skewness* pada data. Gambar 4.4 menunjukkan bahwa terdapat data yang berbeda signifikan dengan mayoritas nilai NPL pada tahun 2004 hingga 2008 sehingga menyebabkan *skewness* pada data. *Skewness* yang terjadi mengindikasikan bahwa data tidak berdistribusi normal secara univariat. Adanya titik yang

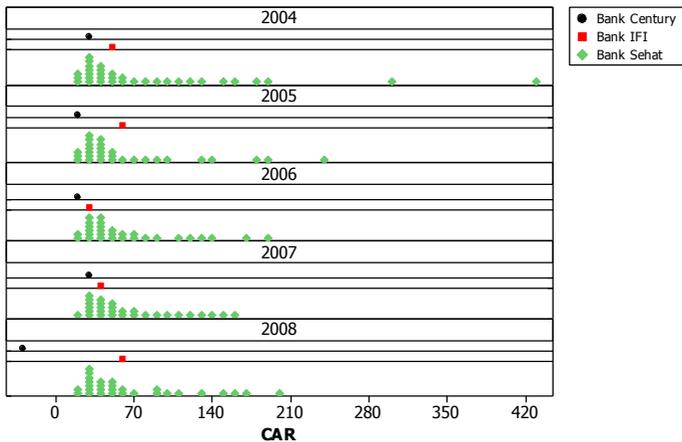
terpencar jauh menandakan bahwa terdapat data *outlier*. Penelitian ini tidak melakukan penanganan terhadap *outlier* yang terjadi. Gambar 4.4 menunjukkan bahwa terdapat beberapa bank sehat yang memiliki nilai NPL lebih buruk dari Bank IFI maupun Bank Century. Namun, cepatnya proses pemulihan pada bank tidak mengakibatkan bank dilikuidasi. Rasio keuangan lainnya adalah CAR.

Selain NPL, rasio perbankan yang juga disebutkan dalam POJK nomor 15/POJK.03/2017 adalah CAR. Gambar 4.5 menunjukkan perbedaan nilai CAR dari bank sehat dan bank yang mengalami *financial distress*.



Gambar 4.5 Rata-Rata Prosentase CAR Bank Sehat dan Prosentase CAR Bank dengan *Financial Distress*

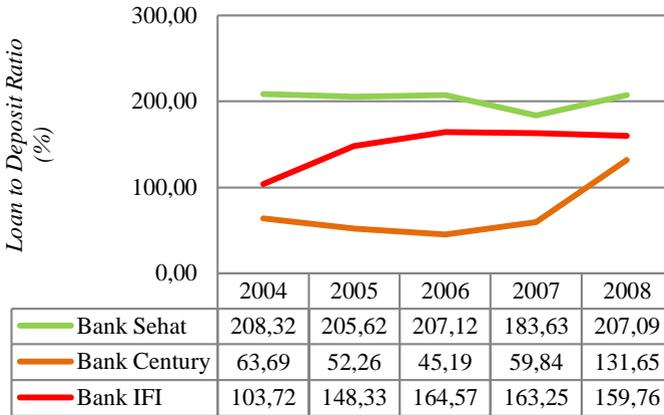
Nilai CAR Bank Century turun secara signifikan pada tahun 2008. Penurunan yang signifikan dari 27,57% menjadi bernilai -26,71% menunjukkan bahwa kemampuan Bank Century dalam menanggung risiko kredit maupun aktiva semakin buruk tahun 2008. Berbeda dengan Bank Century, Bank IFI menunjukkan kenaikan nilai CAR pada tahun 2008. Namun, tingginya kredit bermasalah bank IFI pada tahun 2008 masih menjadi masalah yang dihadapi bank IFI pada tahun 2008. Gambar 4.6 merupakan *dot plot* untuk variabel CAR.



Gambar 4.6 Dot Plot CAR Bank Umum Tahun 2004-2008

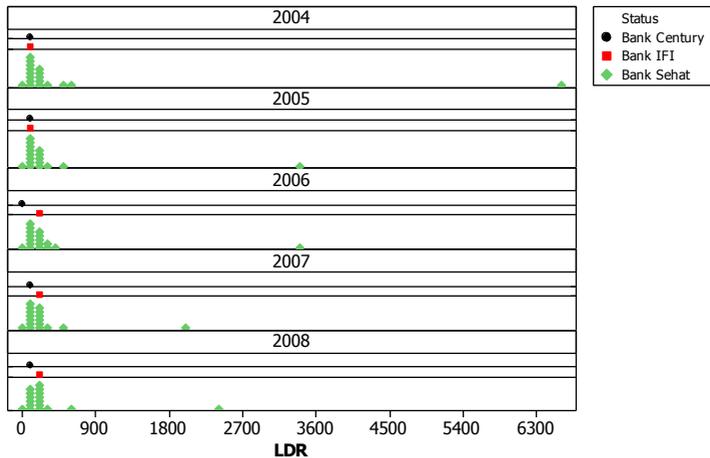
Serupa dengan variabel NPL, pada variabel CAR terlihat bahwa data mengalami *skewness* dimana puncak grafik tidak berada tepat ditengah. Hal ini dikarenakan adanya data yang terpisah jauh. Seperti yang terjadi pada tahun 2004 dimana terdapat satu data yang bernilai sekitar 420% dimana data terbanyak hanya terletak pada kisaran 40-50%. Data yang terpencar jauh diindikasikan sebagai data *outlier*. Gambar 4.6 menunjukkan bahwa dari tahun ke tahun Bank IFI dan Bank Century memiliki nilai CAR yang hampir serupa dengan mayoritas bank sehat di Indonesia. Namun pada tahun 2008, nilai CAR dari Bank Century terlihat berbeda signifikan dengan bank sehat lainnya.

Rasio keuangan lain yang digunakan dalam penelitian ini adalah LDR, ROA, ROE, NIM, BOPO, aktiva produktif bermasalah, PPAP terhadap aktiva produktif, pemenuhan PPAP, dan ATTM. Gambar 4.7 menunjukkan perbandingan rasio LDR dari bank sehat dan bank yang telah dilikuidasi oleh pemerintah dari tahun 2004 hingga tahun 2008.



Gambar 4.7 Rata-rata Perentase LDR Bank Sehat dan Prosentase LDR Bank dengan *Financial Distress*

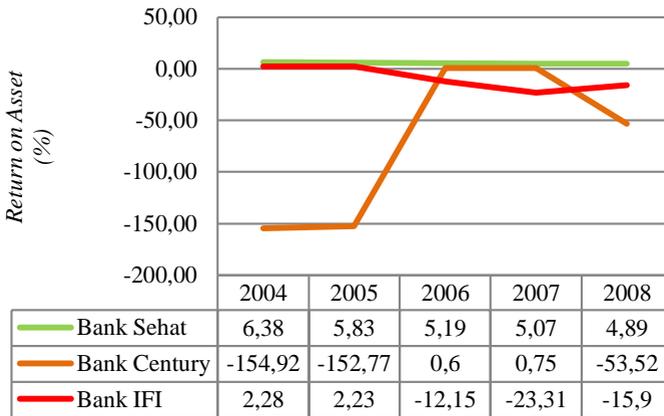
Rasio keuangan LDR adalah rasio keuangan perbankan yang dapat menunjukkan apakah suatu bank dapat dikatakan likuid atau tidak. Jika LDR bernilai terlalu tinggi artinya bank tidak memiliki kemampuan yang cukup baik dalam memenuhi kewajibannya terhadap nasabah yang dapat diartikan bank tersebut menjadi tidak likuid. Sedangkan nilai LDR yang kecil mengabarkan bank tersebut memiliki likuiditas yang cukup baik. Namun, kecilnya nilai LDR dapat berdampak pada keuntungan yang dimiliki oleh bank mengingat pendapatan terbesar yang didapat bidang perbankan berasal dari kredit yang disalurkan. Gambar 4.7 menunjukkan bahwa LDR dari Bank Century dan bank Bank IFI lebih rendah dari bank sehat lainnya dari tahun 2004 hingga tahun 2008. Gambar 4.8 merupakan *dot plot* dari variabel LDR tuntut tahun 2004 hingga tahun 2008.



Gambar 4.8 Dot Plot LDR Bank Umum Tahun 2004-2008

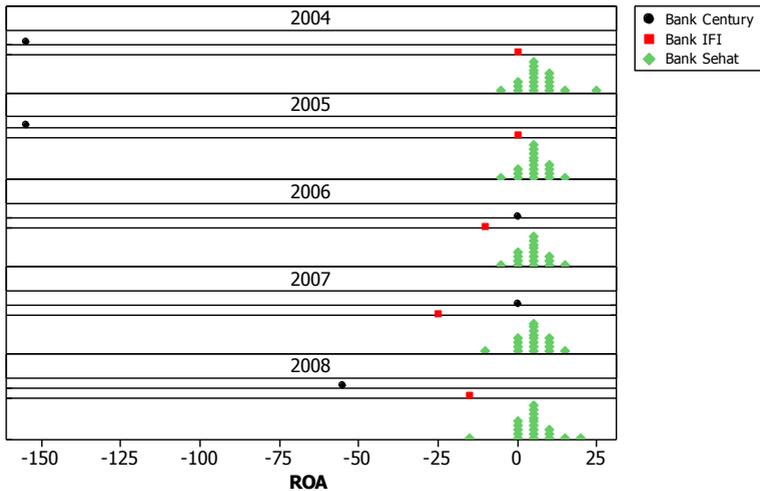
Data variabel LDR terlihat *skew* kanan, dimana data menumpuk disebelah kanan sedangkan terdapat sedikit data yang terpisah jauh disebelah kiri yang menyebabkan ekor distribusi menjadi panjang di satu sisi. Terdapat data yang jauh terpisah pada tahun 2004. Data tersebut bernilai 6684,97 sedangkan data lainnya hanya berkisar pada nilai 100 hingga 200. Tahun 2005 hingga 2008 juga memiliki permasalahan yang serupa. Terdapat satu data yang secara signifikan berbeda dengan median data variabel LDR. Data-data yang terpencar jauh dari data-data lainnya diindikasikan sebagai data penciran atau data *outlier*. Bentuk *plot* yang tidak simetris juga menandakan bahwa data untuk variabel LDR tidak berdistribusi normal secara univariat.

Rasio keuangan lainnya yang dapat diperhatikan dalam melihat kondisi keuangan suatu bank adalah ROA atau *return on asset*. Gambar 4.9 menggambarkan ROA dari rata-rata bank sehat dengan ROA dari Bank Century dan Bank IFI yang merupakan bank yang mengalami *financial distress* dan dilikuidasi oleh pemerintah pada tahun 2008.



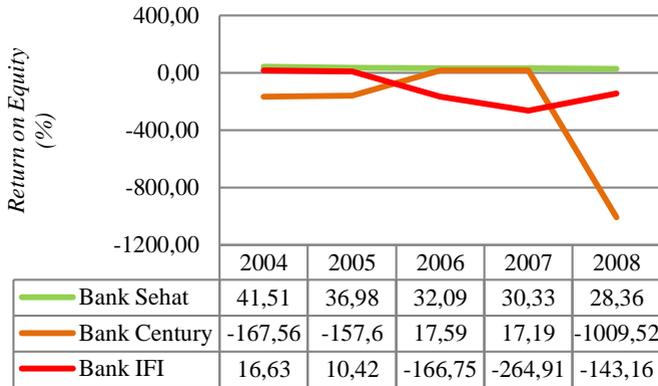
Gambar 4.9 Rata-Rata Prosentase ROA Bank Sehat dan Prosentase ROA Bank dengan *Financial Distress*

ROA Bank Century mengalami kenaikan signifikan dari tahun 2005 menuju tahun 2006. Nilai tersebut sempat bertahan hingga tahun 2007 namun kembali turun pada tahun 2008. Berbeda dengan Bank Century, Bank IFI telah mengalami penurunan nilai ROA sejak tahun 2005, walaupun sempat mengalami kenaikan pada tahun 2008. Kecilnya nilai ROA kedua bank tersebut yang berada cukup jauh dari rata-rata bank yang ada saat itu menunjukkan kondisi yang kurang baik. Kecilnya ROA menunjukkan bahwa kemampuan bank tersebut untuk menghasilkan laba juga sangat kecil. pada Bank Century dan Bank IFI bahkan mencapai nilai negatif yang menunjukkan kedua bank tersebut mengalami kerugian. Gambaran mengenai ROA bank umum di Indonesia pada tahun 2004 hingga 2008 juga dapat digambarkan dalam sebuah *dot plot*. Gambar 4.10 merupakan *dot plot* dari variabel ROA bank umum di Indonesia pada tahun 2004 sampai dengan tahun 2008.



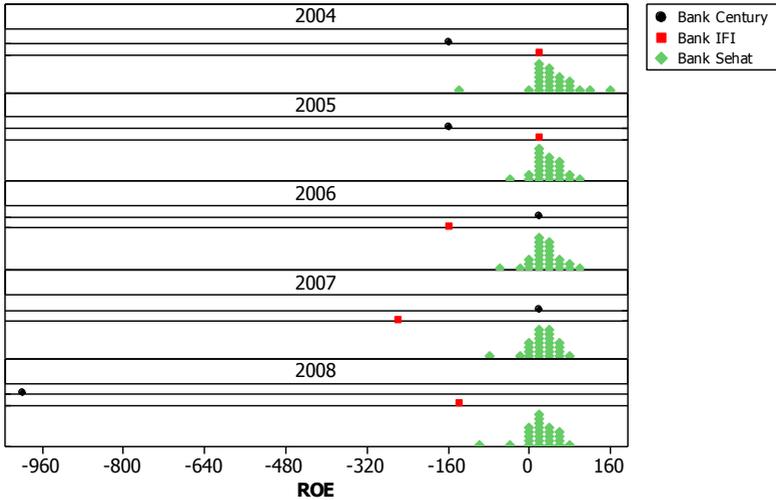
Gambar 4.10 Dot Plot ROA Bank Umum Tahun 2004-2008

Berbeda dengan variabel CAR, LDR, dan NPL yang menunjukkan *dot plot* dengan *skew* kanan, variabel ROA menunjukkan *dot plot* dengan *skew* kiri. ROA yang bernilai negatif menunjukkan performa bank yang kurang baik. dengan nilai negatif terbesar berada pada kisaran -150. Sejak tahun 2004, Bank Century telah menunjukkan indikasi *financial distress*. Hal ini terlihat dari nilai ROA Bank Century yang jauh lebih kecil dari mayoritas bank sehat. Gambar 4.11 menunjukkan perbandingan nilai ROE bank sehat dan bank dengan kondisi *financial distress*.



Gambar 4.11 Rata-Rata Prosentase ROE Bank Sehat dan Prosentase ROE Bank dengan *Financial Distress*

Tahun 2008 Bank Century terlihat mengalami permasalahan serius. Hal ini terlihat dari turunnya nilai ROE Bank Century hingga menembus angka -1009,52%. Bank IFI juga menunjukkan hal yang serupa dimana ROE Bank IFI tahun 2008 menyentuk angka -143,16%. Kecilnya nilai ROE kedua bank ini menggambarkan bahwa kemampuan bank untuk mengembalikan modal yang ditanamkan juga rendah. Karakteristik nilai ROE juga dapat digambarkan kedalam *dot plot*. *Dot plot* dari variabel ROE digambarkan pada Gambar 4.12.

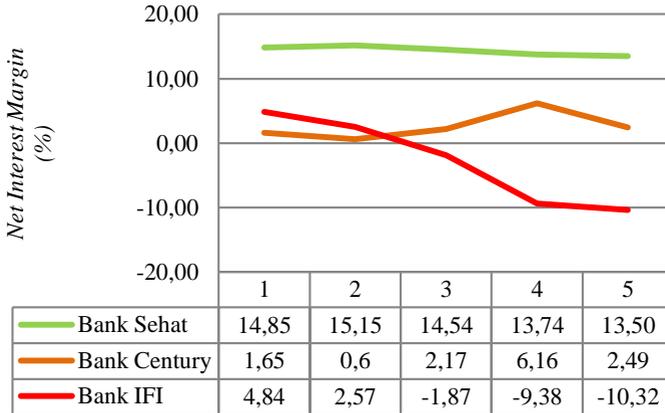


Gambar 4.12 Dot Plot ROE Bank Umum Tahun 2004-2008

Serupa dengan ROE, *dot plot* untuk variabel ROE menunjukkan terjadinya *skewness* ke arah kiri. Hal ini menunjukkan bahwa terdapat beberapa bank pada tahun 2004 hingga tahun 2008 yang memiliki kemampuan yang rendah dalam pengembalian modal yang telah ditanamkan. Jumlah titik yang terpecah dari tahun 2004 hingga tahun 2008 yang berjumlah lebih dari dua titik menunjukkan bahwa bukan hanya Bank Century dan Bank IFI yang mengalami penurunan performa pada lima tahun tersebut. Data yang terpisah jauh mengindikasikan bahwa terdapat data yang dikategorikan sebagai *outlier*. Namun, penanganan *outlier* tidak dilakukan mengingat karakteristik dari bank dengan kondisi *financial distress* bias jadi digambarkan oleh data-data *outlier* tersebut. Gambar 4.12 menunjukkan bahwa nilai ROE Bank IFI dan Bank Century berada lebih rendah dari rata-rata bank sehat lainnya.

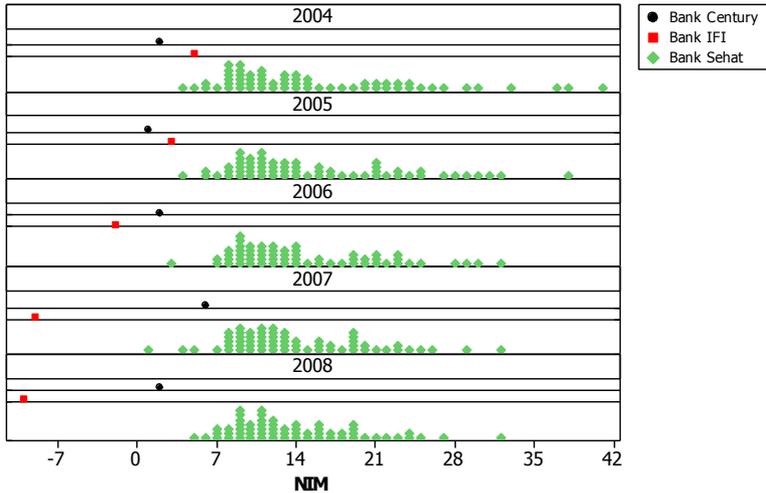
Variabel lain yang juga digunakan pada penelitian ini adalah variabel NIM atau *net interest margin*. Gambar 4.13

menunjukkan perbedaan nilai NIM dari bank sehat dan bank yang mengalami *financial distress*.



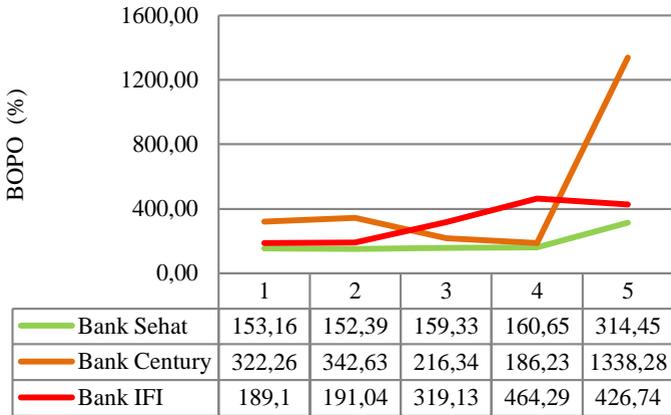
Gambar 4.13 Rata-Rata Prosentase NIM Bank Sehat dan Prosentase NIM Bank dengan *Financial Distress*

Nilai NIM dari Bank Century dan Bank IFI tahun 2004 hingga 2008 terlihat berada di bawah rata-rata bank lainnya kala itu. Bank IFI sejak tahun 2006 yang terus memburuh hingga tahun 2008 menunjukkan ketidakmampuan Bank IFI untuk mengelola aktiva produktif yang dimiliki untuk menghasilkan laba bunga bersih. NIM dari Bank Century sempat mengalami kenaikan pada tahun 2007 namun kembali memburuh pada tahun 2008 hingga pemerintah mengambil keputusan untuk melikuidasi Bank Century. *Dot plot* digunakan untuk menggambarkan variabel NIM pada seluruh bank umum di Indonesia pada tahun 2004 hingga tahun 2008. Gambar 4.14 merupakan *dot plot* dari variabel NIM seluruh bank umum di Indonesia pada tahun 2004 hingga tahun 2008.



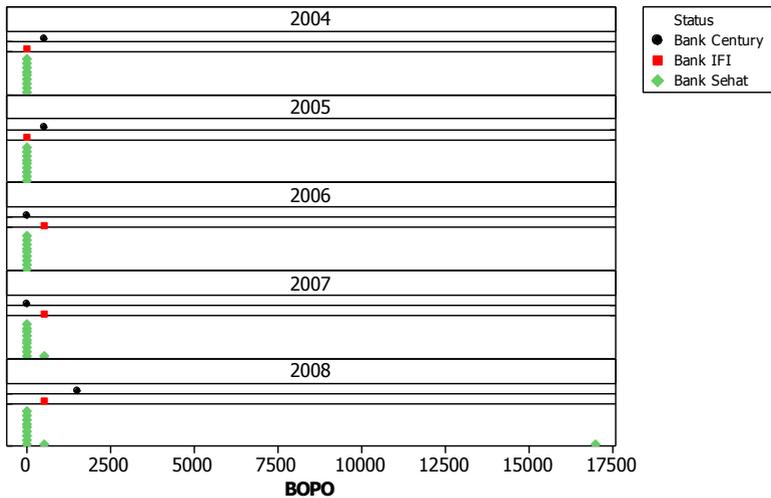
Gambar 4.14 Dot Plot NIM Bank Umum Tahun 2004-2008

Dot plot untuk variabel NIM menunjukkan bahwa data cenderung simetris walaupun terdapat beberapa data yang terpecar jauh. *Dot plot* tahun 2004 terlihat menunjukkan terjadinya *skewness* dikarenakan puncak dari plot tidak berada di tengah plot. Tahun 2005 hingga 2008 terlihat lebih simetris dimana puncak plot terlihat berada di tengah plot walaupun tidak tepat ditengah. Namun, untuk plot tahun 2004 hingga 2008 terlihat bahwa plot memiliki lebih dari satu puncak dimana hal ini mengindikasikan bahwa distribusi dari data NIM memiliki nilai parameter yang lebih dari satu macam. Variabel yang akan dianalisis selanjutnya adalah variabel BOPO. Variabel BOPO dari rata-rata bank sehat akan dibandingkan dengan nilai BOPO dari Bank Century dan Bank IFI yang merupakan bank dengan kondisi *financial distress*. Perbandingan nilai BOPO akan ditunjukkan pada Gambar 4.15.



Gambar 4.15 Rata-Rata Prosentase BOPO Bank Sehat dan Prosentase BOPO Bank dengan *Financial Distress*

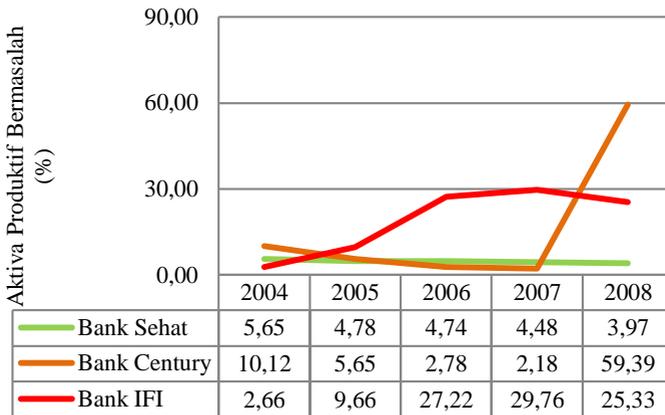
Gambar 4.15 menunjukkan adanya kenaikan yang signifikan pada nilai rasio BOPO Bank Century dari nilai 186,23% pada tahun 2007 menjadi 1338,28% pada tahun 2008. Berbanding terbalik dengan Bank Century, Bank IFI justru mengalami penurunan nilai rasio BOPO pada tahun 2008. Rasio BOPO merupakan perbandingan antara beban operasional yang ditanggung bank dengan pendapatan operasional bank. Nilai BOPO Bank Century yang naik signifikan pada tahun 2008 meunjukkan bahwa operasional bank kala itu sangat tidak efektif dikarenakan beban operasional lebih besar 1338,28 kali lebih besar dari pendapatan operasionalnya. Analisis mengenai karakteristik rasio BOPO akan digambarkan dalam *dot plot*. Gambar 4.16 merupakan *dot plot* dari variabel BOPO bank umum di Indonesia pada tahun 2004 hingga tahun 2008.



Gambar 4.16 Dot Plot BOPO Bank Umum Tahun 2004-2008

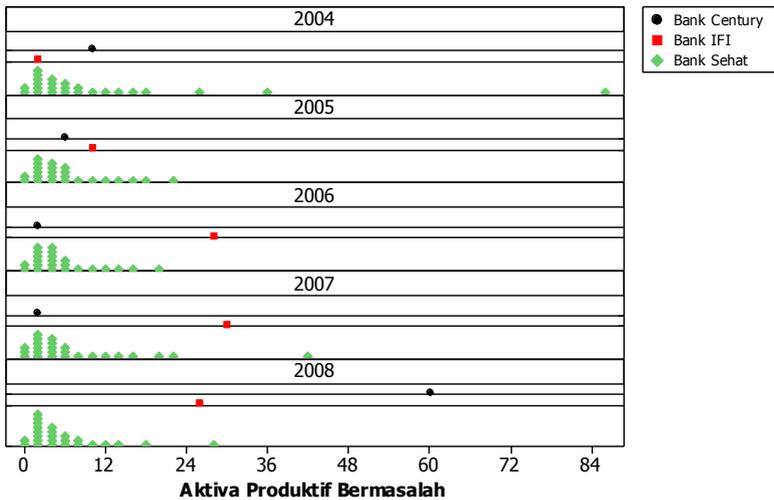
Tahun 2004 hingga tahun 2007 tidak menunjukkan adanya data yang diindikasikan sebagai data *outlier*. Rasio BOPO pada tahun 2004 hingga tahun 2008 menunjukkan bahwa rata-rata rasio BOPO haampir menyerupai median data. Hal ini ditunjukkan dengan menumpuknya data pada satu titik dan data lain yang terpisah tidak berbeda secara signifikan. Namun, pada tahun 2008 terdapat satu nilai yang berbeda signifikan dengan data secara keseluruhan. Data BOPO secara umum bernilai puluhan dimana satu data terpencar berada pada kisaran nilai 17500. Data ini diindikasikan sebagai data *outlier*. Sama halnya dengan variabel lainnya, data *outlier* pada variabel BOPO tidak ditangani. Hal ini karena penelitian ini berfokus pada bank dengan kondisi *financial distress* yang kemungkinan memuat data dengan nilai-nilai yang termasuk data *outlier*. Variabel lain yang juga digunakan dalam penelitian ini adalah variabel aktiva produktif bermasalah. Gambar 4.17 merupakan plot yang membandingkan nilai rasio aktiva produktif bermasalah dari bank sehat dan bank yang

mengalami kondisi *financial distress* yaitu Bank Century dan Bank IFI.



Gambar 4.17 Rata-Rata Presentase Aktiva Produktif Bermasalah Bank Sehat dan Presentase Aktiva Produktif Bermasalah Bank dengan *Financial Distress*

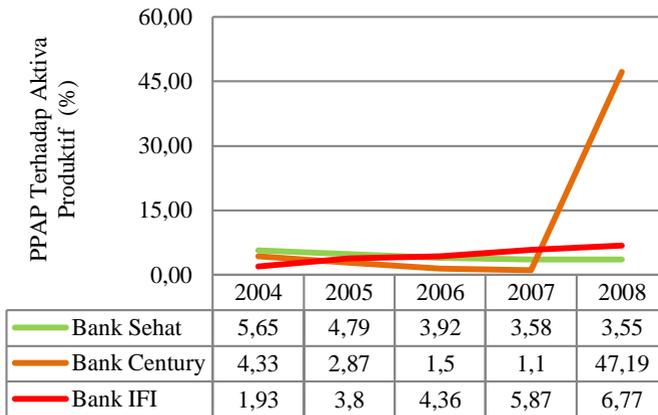
Rasio lain yang juga dapat menjadi perhatian adalah rasio aktiva produktif bermasalah. Gambar 4.17 menunjukkan bahwa Bank Century mengalami peningkatan rasio aktiva produktif bermasalah yaitu dari nilai 2,18 pada tahun 2007 menjadi 59,39% pada tahun 2008. Hal ini berarti jumlah aktiva produktif bermasalah dari total aktiva produktifnya mencapai angka 59,39%. Berbeda dengan Bank Century, Bank IFI telah mengalami kenaikan rasio aktiva produktif bermasalah sejak tahun 2006 hingga tahun 2008. Pada akhir tahun 2008, nilai rasio aktiva produktif bermasalah Bank IFI mencapai angka 25,33%. Karakteristik dari rasio aktiva produktif bermasalah juga akan digambarkan dengan menggunakan *dot plot*. Gambar 4.18 merupakan *dot plot* dari rasio aktiva produktif bermasalah dari bank umum di Indonesia tahun 2004 hingga tahun 2008.



Gambar 4.18 Dot Plot Aktiva Produktif Bermasalah Bank Umum Tahun 2004-2008

Setiap tahun dari tahun 2004 hingga tahun 2008 memiliki data yang diindikasikan sebagai data *outlier*. Hal ini terlihat dikarenakan pada masing-masing tahun terdapat data yang terlihat terpencar jauh dari data lainnya. Data dengan nilai yang paling tinggi berada pada tahun 2004 yaitu berada pada nilai diatas 80%. Tingginya aktiva produktif bermasalah ini menandakan bahwa dari keseluruhan total aktiva yang dimiliki bank tersebut, 80% diantaranya merupakan aktiva produktif yang bermasalah. Gambar 4.18 menunjukkan bahwa data dengan nilai yang berbeda signifikan dengan data lainnya berjumlah lebih dari dua. Hal ini mengindikasikan bahwa selain Bank IFI dan Bank Century, terdapat bank umum lainnya yang mengalami masalah keuangan baik dalam skala besar atau kecil. Data yang cenderung condong ke satu sisi menandakan bahwa data tidak berdistribusi normal secara univariat. Variabel selanjutnya adalah PPAP terhadap aktiva produktif. Gambar 4.19 menggambarkan perbedaan rasio PPAP terhadap

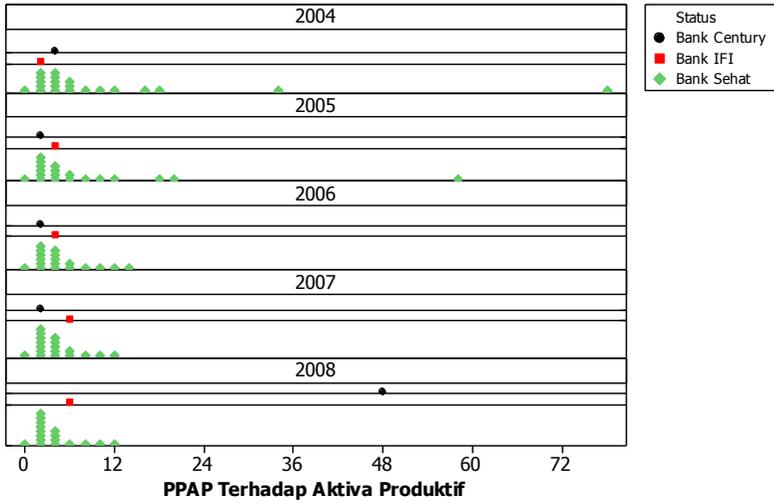
aktiva produktif bermasalah dari bank sehat dan bank dengan *financial distress*.



Gambar 4.19 Rata-Rata Prosentase PPAP Terhadap Aktiva Produktif Bank Sehat dan Prosentase PPAP Terhadap Aktiva Produktif Bank dengan *Financial Distress*

Penyisihan Penghapusan Aktiva Produktif (PPAP) terhadap aktiva produktif merupakan perbandingan antara PPAP yang telah terbentuk dengan total aktiva produktif. Rasio PPAP terhadap aktiva produktif menunjukkan jumlah cadangan yang harus disediakan oleh bank untuk mengatasi risiko memburuhnya kondisi aktiva produktif. Bank IFI memiliki rasio PPAP terhadap aktiva produktif yang cukup bank walaupun terjadi peningkatan dari tahun ke tahun. Performa dari Bank Century terlihat berbeda dari Bank IFI. Hal ini terlihat dari naiknya nilai rasio PPAP terhadap aktiva produktif dari sebelumnya hanya bernilai 1,1% pada tahun 2007 menjadi 47,19% pada tahun 2008. Naiknya nilai rasio ini menunjukkan bahwa aktiva bermasalah Bank Century tergolong tinggi pada tahun 2008. *Dot plot* dari rasio PPAP terhadap aktiva produktif digunakan untuk melihat rasio PPAP terhadap rasio keuangan untuk seluruh bank umum di

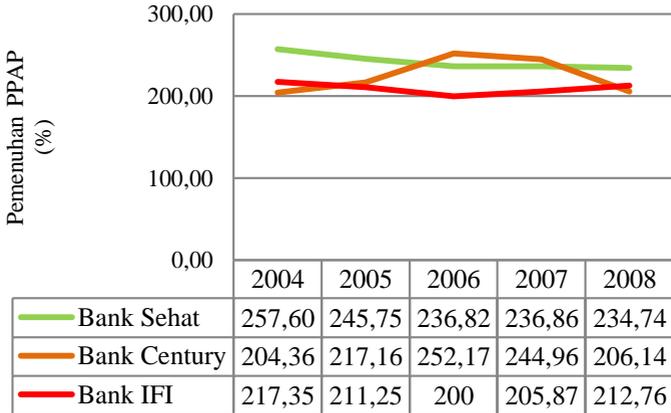
Indonesia pada tahun 2004 hingga tahun 2008. Gambar 4.20 merupakan *dotplot* dari rasio PPAP terhadap aktiva produktif.



Gambar 4.20 *Dot Plot* PPAP terhadap Aktiva Produktif Bank Umum Tahun 2004-2008

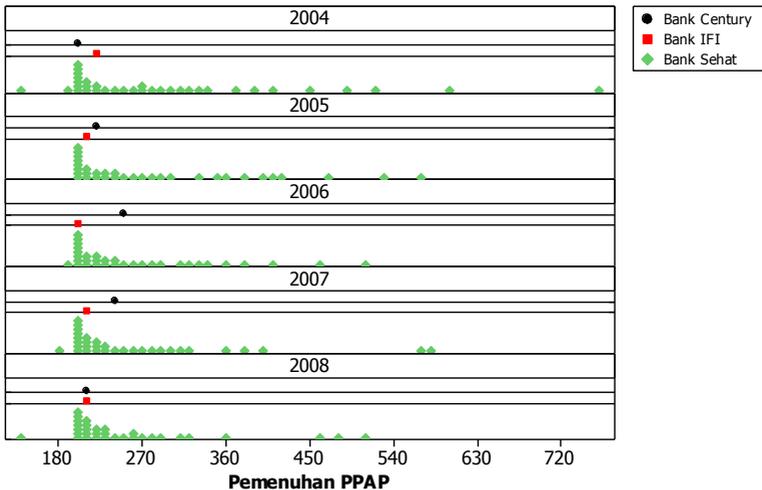
Nilai rasio PPAP terhadap aktiva produktif tertinggi ada pada tahun 2004 dimana rasio PPAP terhadap aktiva produktif bernilai lebih dari 70%. Secara keseluruhan dari tahun 2004 hingga tahun 2008 mengandung data yang diindikasikan sebagai data *outlier*. Hal ini terlihat dari adanya titik-titik yang berada cukup jauh dari data-data lainnya. Tahun 2004, terdapat beberapa bank yang memiliki rasio PPAP terhadap aktiva produktif yang buruh. Bank tersebut berasal dari kategori bank sehat baru pada tahun 2008, Bank Century terlihat mengalami permasalahan yang ditunjukkan dengan tingginya nilai rasio PPAP terhadap aktiva produktif bermasalah. Analisis selanjutnya adalah mengenai karakteristik dari variabel rasio pemenuhan PPAP. Rasio pemenuhan PPAP dari bank yang sehat akan dibandingkan dengan rasio pemenuhan PPAP dari Bank Century dan Bank IFI yang merupakan bank dengan

kondisi *financial distress*. Gambar 4.21 merupakan grafik yang membandingkan rasio-rasio tersebut.



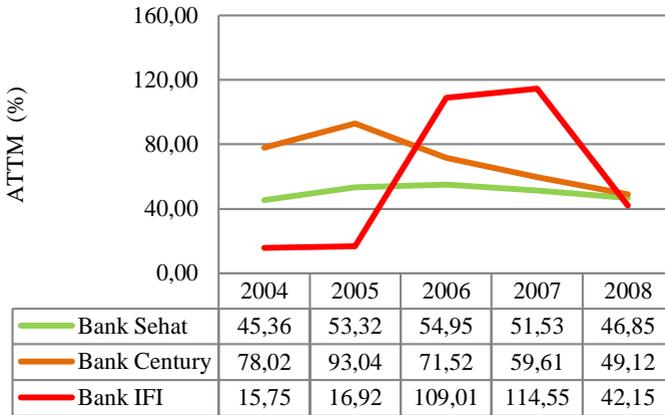
Gambar 4.21 Rasa-Rasa Prosentase Pemenuhan PPAP Bank Sehat dan Prosentase Pemenuhan PPAP Bank dengan *Financial Distress*

Rasio pemenuhan PPAP merupakan rasio antara PPAP yang telah dibentuk terhadap PPAP yang wajib dibentuk. Nilai PPAP untuk Bank Century dan Bank IFI terlihat cukup baik. Nilai rasio pemenuhan PPAP yang bernilai lebih dari 100% menunjukkan bahwa PPAP yang telah dibentuk bernilai lebih besar dari PPAP yang wajib dibentuk. Hal ini berarti bank telah siap menanggung risiko kehilangan aktiva produktif. Analisis terhadap variabel pemenuhan PPAP tidak hanya dilakukan dengan membandingkan rata-rata rasio pemenuhan PPAP bank sehat dengan bank dengan kondisi *financial distress*. *Dot plot* digunakan untuk menganalisis karakteristik dari rasio pemenuhan PPAP dari bank umum di Indonesia dari tahun 2004 hingga tahun 2008. Gambar 4.22 merupakan *dot plot* untuk variabel pemenuhan PPAP.



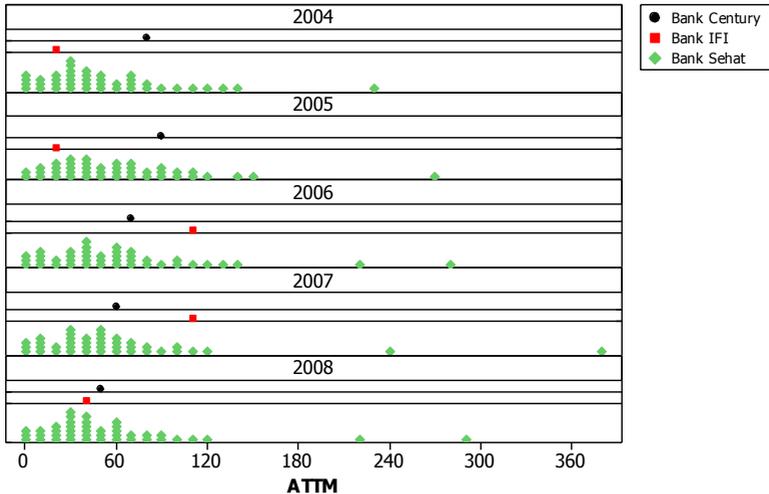
Gambar 4.22 Dot Plot Pemenuhan PPAP Bank Umum Tahun 2004-2008

Serupa dengan beberapa rasio keuangan lainnya, rasio pemenuhan PPAP juga terlihat memiliki data yang diindikasikan sebagai data *outlier*. Hal ini dikarena terdapat beberapa titik yang terpecah cukup jauh dari data-data lainnya. Tahun 2004 memiliki data pemenuhan PPAP dengan nilai tertinggi. Tahun 2004 dan 2008 memiliki nilai rasio pemenuhan PPAP yang bernilai dibawah data-data lainnya. Variabel lainnya yang akan dianalisis adalah rasio ATTM. Gambar 4.23 merupakan gambaran rasio ATTM tahun 2004 hingga 2008.



Gambar 4.23 Rata-Rata Prosentase ATTM Bank Sehat dan Prosentase ATTM Bank dengan *Financial Distress*

Nilai rasio ATTM yang tinggi menunjukkan bahwa modal tidak mencukupi aktiva produktif serta inventaris yang dibutuhkan bank. Rasio ATTM Bank IFI mengalami kenaikan yang signifikan pada tahun 2006 namun kembali turun pada tahun 2008, sedangkan rasio ATTM Bank Century secara konsisten turun hingga tahun 2008. Karakteristik dari rasio ATTM juga dapat dianalisis dengan menggunakan *dot plot*. Gambar 4.24 merupakan *dot plot* dari rasio ATTM.



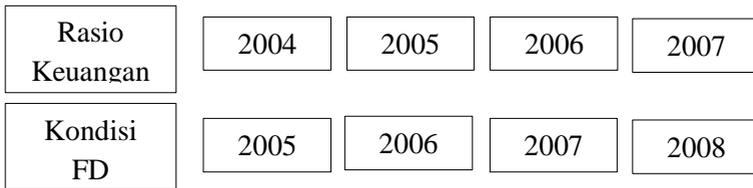
Gambar 4.24 Dot Plot ATTM Bank Umum Tahun 2004-2008

Data tahun 2004 hingga tahun 2008 untuk rasio ATTM terlihat mengandung data *outlier*. Hal ini terlihat dari adanya titik-titik yang terpencar jauh dari data-data yang lainnya. Keberadaan data *outlier* menyebabkan plot menjadi condong pada satu sisi. Hal ini mengakibatkan data diduga tidak berdistribusi normal. Nilai ATTM yang tinggi pada tahun 2004-2008 justru didominasi oleh bank sehat. Tingginya rasio ATTM menunjukkan bahwa bank tidak memiliki modal yang cukup.

Secara keseluruhan, beberapa kondisi rasio keuangan telah menunjukkan bahwa Bank Century dan Bank IFI mengalami penurunan performa secara signifikan pada tahun 2008. Perbedaan pola terlihat antara Bank IFI dan Bank Century. Bank IFI terlihat menunjukkan penurunan performa secara perlahan sejak tahun 2005 hingga 2008, sedangkan Bank Century menunjukkan penurunan performa secara signifikan pada tahun 2008. Hal ini mengindikasikan bahwa kedua bank tersebut mengalami *financial distress*.

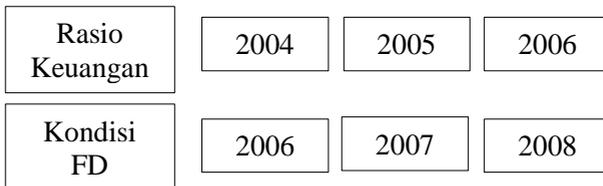
4.3 Window Size Pada Data Kondisi Keuangan Perbankan

Penggunaan *window size* dengan metode *full memory time window* bertujuan untuk melihat pengaruh kondisi ekonomi pada tahun-tahun sebelumnya dalam prediksi kondisi bank yang akan mendatang. Digunakan tiga skema *window size* dengan metode *full memory time window*. Skema *full memory time window* untuk $size = 1$ diilustrasikan pada Gambar 4.25.



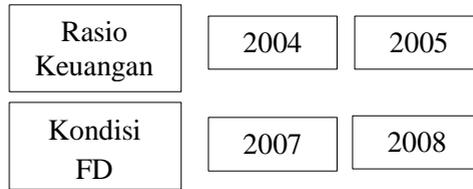
Gambar 4.25 Full Memory Time Window Untuk Size = 1

Pada skema *full memory time window* dengan $size = 1$ digunakan rasio keuangan tahun 2004 untuk kondisi bank tahun 2005, rasio keuangan tahun 2005 untuk kondisi bank tahun 2006, dan seterusnya hingga rasio tahun 2007 untuk kondisi bank tahun 2008. Skema *full memory time window* untuk $size = 2$ digambarkan pada Gambar 4.26.



Gambar 4.26 Full Memory Time Window Untuk Size = 2

Pada skema *full memory time window* dengan $size = 2$ digunakan rasio keuangan tahun 2004 untuk kondisi bank tahun 2006, rasio keuangan tahun 2005 untuk kondisi bank tahun 2007, dan rasio tahun 2006 untuk kondisi bank tahun 2008. Skema *full memory time window* untuk $size = 3$ diilustrasikan pada Gambar 4.27.



Gambar 4.27 Full Memory Time Window Untuk Size = 3

Skema *full memory time window* dengan nilai *size* = 3 menggunakan data rasio keuangan tahun 2004 untuk kondisi ekonomi tahun 2007 dan data rasio keuangan tahun 2005 untuk data kondisi bank tahun 2008.

Rasio-rasio keuangan yang ditetapkan oleh BI dalam surat edarannya diindikasikan memiliki hubungan erat antar rasio-rasio keuangan. Semakin besar hubungan antar rasio keuangan akan menghasilkan analisis yang kurang baik. Oleh karena itu dilakukan pemeriksaan terhadap korelasi antar rasio keuangan bank dari tahun 2004 hingga tahun 2008. Gambar 4.28 menunjukkan *heatmap* dari rasio keuangan bank tahun 2004 hingga 2008.



Gambar 4.28 Heatmap Rasio Keuangan Bank

Semakin pudar warna pada *heatmap* manandakan kecilnya hubungan antara rasio keuangan. *Heatmap* pada Gambar 4.28 menunjukkan adanya hubungan yang besar antara tiga rasio keuangan yaitu rasio aktiva produktif bermasalah, NPL, dan PPAP terhadap aktiva produktif. Hal ini dapat disebabkan adanya satu variabel yang sama yang digunakan pada perhitungan ketiga rasio tersebut, seperti dalam perhitungan rasio aktiva produktif bermasalah dan perhitungan PPAP terhadap aktiva produktif bermasalah. Kedua rasio ini melibatkan nilai total aktiva produktif dalam perhitungannya. Besarnya hubungan antar rasio ini dapat berdampak pada jumlah variabel yang berpengaruh signifikan terhadap kondisi *financial distress* bank umum di Indonesia. Rasio keuangan selain dari itu menunjukkan nilai korelasi yang kecil. Penelitian ini akan tetap menggunakan seluruh variabel tanpa memperhatikan signifikansi parameter. Oleh karena itu, tidak dilakukan reduksi baik dalam jumlah pengamatan maupun dalam jumlah variabel.

4.4 Pemodelan Prediksi *Financial Distress* dengan Analisis Diskriminan

Langkah awal yang harus dilakukan dalam analisis diskriminan adalah melakukan pengujian apakah asumsi telah dipenuhi atau belum. Asumsi yang harus dipenuhi dalam analisis diskriminan adalah matriks varians kovarians yang bersifat homogen, variabel rasio keuangan, inflasi, dan pertumbuhan ekonomi berdistribusi normal multivariate, serta terdapat perbedaan rata-rata antar kelompok bank sehat dan bank dengan kondisi *financial distress*.

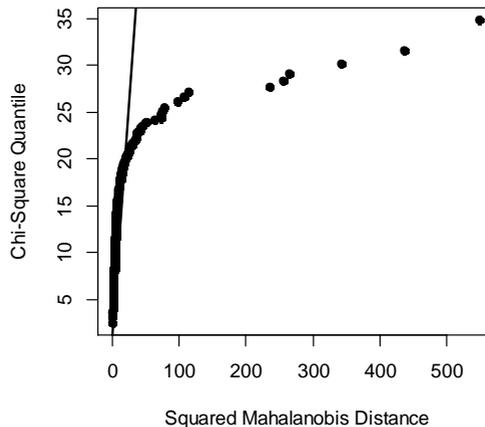
a. Hasil Uji Homogenitas Pada Data Rasio Keuangan dan Kondisi Ekonomi Indonesia

Perhitungan statistik uji dilakukan berdasarkan persamaan (2.6) yang telah dijelaskan pada Bab II Tinjauan Pustaka mengenai uji homogenitas. *P-value* hasil pengujian yang didapatkan adalah sebesar 1. *P-value* yang bernilai lebih

besar dari $\alpha = 0,05$ menyebabkan H_0 gagal ditolak. Artinya, matriks varians kovarians pada data rasio keuangan dan kondisi ekonomi Indonesia telah memenuhi asumsi homogenitas.

b. Hasil Uji Distribusi Normal Multivariat Pada Data Rasio Keuangan dan Kondisi Ekonomi Indonesia

Mardia's test dilakukan untuk menguji apakah data berdistribusi normal multivariate atau tidak. Hasil dari uji normalitas menghasilkan *p-value* yang bernilai 0. *P-value* yang bernilai kurang dari $\alpha = 0,05$ menunjukkan bahwa data rasio keuangan dan kondisi ekonomi Indonesia tidak berdistribusi normal multivariate. Oleh karena itu, asumsi distribusi normal multivariate tidak dapat terpenuhi. Gambar 4.29 menunjukkan qq-plot dari data rasio keuangan dan kondisi ekonomi Indonesia.



Gambar 4.29 *Chi-Squared QQ-Plot* Data Rasio Keuangan, Inflasi, dan Pertumbuhan Ekonomi

Titik-titik hitam pada gambar merepresentasikan data rasio keuangan dan kondisi ekonomi Indonesia secara multivariat. Banyaknya titik-titik yang tersebar jauh dari garis hitam mengindikasikan bahwa data tidak berdistribusi normal multivariat.

b. Hasil Uji Beda Rata-Rata Antara Bank Sehat dan Bank dengan *Financial Distress*

Pengujian dilakukan secara parsial dan serentak. *P-value* dari pengujian serentak bernilai 0. Artinya, minimal terdapat satu variabel yang memiliki perbedaan signifikan dalam rata-rata antara bank sehat dan bank yang mengalami *financial distress*. Perhitungan terhadap nilai statistik uji untuk uji beda rata-rata antar kelompok menghasilkan nilai *wilks' lambda*, statistik uji F, dan *P-value*. Nilai-nilai tersebut tercantum pada Tabel 4.2.

Tabel 4.2 Hasil Uji Beda Rata-Rata Antar Kelompok

	<i>Wilks Lambda</i>	<i>F statistic</i>	<i>p values</i>
LDR	1.000	0.032	0.857
ROA	0.951	28.134	0.000
ROE	0.562	427.329	0.000
NIM	0.974	14.844	0.000
BOPO	0.997	1.861	0.173
Aktiva Produktif Bermasalah	0.875	78.356	0.000
NPL	0.952	27.728	0.000
PPAP Terhadap Aktiva Produktif	0.932	40.087	0.000
Pemenuhan PPAP	0.999	0.447	0.504
CAR	0.997	1.546	0.214
ATTM	1.000	0.030	0.863
Inflasi	1.000	0.262	0.609
Pertumbuhan Ekonomi	0.997	1.425	0.233

Kesimpulan yang didapatkan adalah terdapat beberapa variabel yang memiliki perbedaan rata-rata antara bank gagal dan bank dengan kondisi *financial distress*. Rasio yang memiliki perbedaan rata-rata signifikan antara bank sehat dan bank dengan kondisi *financial distress* adalah rasio ROA, ROE,

aktiva produktif bermasalah, NPL, dan PPAP terhadap aktiva produktif.

d. Pemodelan *Financial Distress* dengan Analisis Diskriminan Linier

Hasil uji homogenitas menunjukkan bahwa matriks varian dan kovarian telah homogen. Oleh karena itu, digunakan metode analisis diskriminan linier untuk memprediksi apakah bank mengalami *financial distress* atau tidak.

d.1 Pemodelan *Financial Distress* dengan Analisis Diskriminan Linier Secara Serentak

Analisis diskriminan dilakukan sebanyak empat kali yaitu untuk $size = 0$ hingga $size = 3$. Pemodelan dilakukan dengan melibatkan 13 variabel prediktor yang terdiri dari 11 variabel rasio keuangan bank, variabel inflasi, dan variabel pertumbuhan ekonomi. Model yang dihasilkan pada masing-masing $size$ terangkum pada Tabel 4.3.

Tabel 4.3 Model Prediksi *Financial Distress* dengan Analisis Diskriminan Linier

<i>Size</i>	Model
0	$\hat{y} = -0,0004x_1 + 0,0348x_2 - 0,0064x_3 - 0,0008x_4$ $+ 0,0194x_5 + 0,0005x_6 + 0,0147x_7$ $- 0,0194x_8 - 0,0005x_9 + 0,0042x_{10}$ $- 0,0077x_{11} + 0,0275M_1 - 0,1898M_2$
1	$\hat{y} = 0,0001x_1 + 0,0492x_2 - 0,0178x_3 + 0,0004x_4$ $+ 0,0149x_5 - 0,0144x_6 + 0,0969x_7$ $- 0,1771x_8 + 0,0031x_9 - 0,0054x_{10}$ $- 0,0069x_{11} - 0,0116M_1 + 0,4293M_2$
2	$\hat{y} = -0,0001x_1 + 0,0575x_2 - 0,0250x_3 - 0,0242x_4$ $+ 0,0129x_5 - 0,0424x_6 + 0,0652x_7$ $- 0,0685x_8 + 0,0022x_9 - 0,0057x_{10}$ $- 0,0004x_{11} - 0,0565M_1 + 0,9345M_2$
3	$\hat{y} = -0,0001x_1 - 0,1145x_2 + 0,0063x_3 + 0,0003x_4$ $- 0,0013x_5 + 0,0381x_6 + 0,0031x_7$ $- 0,0245x_8 - 0,0006x_9 + 0,0033x_{10}$ $- 0,0054x_{11} + 0,0112M_1 + 0,1990M_2$

Model yang tercantum pada Tabel 4.3 merupakan model yang terbentuk dari data *training*. Uji signifikansi dilakukan untuk mengetahui variabel yang berpengaruh secara signifikan terhadap kondisi *financial distress* suatu bank di Indonesia. Tabel 4.4 menunjukkan variabel yang secara signifikan berpengaruh terhadap kondisi *financial distress* suatu bank.

Tabel 4.4 Variabel yang Berpengaruh Signifikan Pada Metode Analisis Diskriminan Secara Serentak

Size	Variabel	Jumlah
0	Seluruh variabel	13
1	Seluruh variabel	13
2	Seluruh variabel	13
3	Seluruh variabel	13

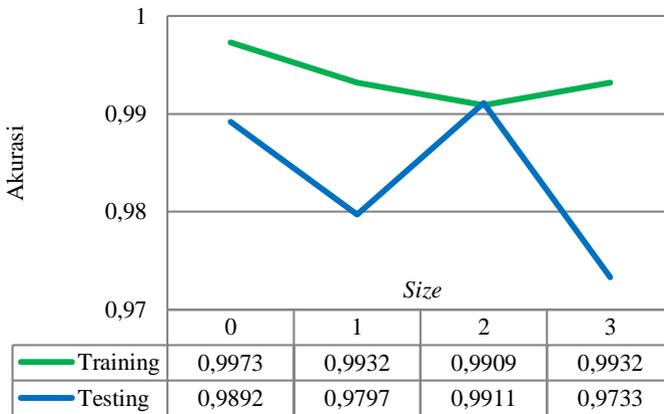
Uji signifikansi menyatakan bahwa seluruh variabel pada model berpengaruh secara signifikan terhadap kondisi keuangan bank. Langkah selanjutnya adalah menggunakan model data *training* untuk mengklasifikasikan data *testing*. Tabel 4.5 merangkum nilai ketepatan klasifikasi bank *financial distress* dengan metode analisis diskriminan linier.

Tabel 4.5 Ketepatan Klasifikasi Analisis Diskriminan Linier

Size	Training		Testing	
	Akurasi	AUC	Akurasi	AUC
0	0,9973	0,7500	0,9892	0,7473
1	0,9932	0,7483	0,9797	0,7432
2	0,9909	0,7477	0,9911	0,7500
3	0,9932	0,7500	0,9733	0,7432

Nilai akurasi baik untuk data *training* maupun untuk data *testing* yang bernilai lebih besar dari 0,95 menandakan bahwa klasifikasi bank dengan metode analisis diskriminan linier telah menghasilkan klasifikasi yang baik. Nilai AUC yang berada disekitar nilai 0,75 menandakan klasifikasi yang dilakukan masih berada pada kategori *fair classification*. Hal ini dikarenakan terjadinya kesalahan klasifikasi dimana bank dengan kondisi *financial distress* diklasifikasikan sebagai bank sehat sehingga nilai AUC menjadi kurang baik. Kesalahan

klasifikasi dari metode analisis diskriminan ini adalah bank dengan kondisi *financial distress* diklasifikasikan sebagai bank sehat. Hal ini berpengaruh dalam memperkecil nilai AUC hasil klasifikasi. Gambar 4.30 menunjukkan fluktuasi nilai akurasi dari data *training* dan data *testing*.



Gambar 4.30 Nilai Akurasi Metode Analisis Diskriminan Linier

Gambar 4.30 menunjukkan bahwa nilai akurasi tertinggi dari data *training* maupun data *testing* pada metode analisis diskriminan linier berapa pada *window size* 2 yaitu pada kondisi dimana data rasio dan kondisi makroekonomi tahun 2004 digunakan untuk memprediksi kondisi *financial distress* tahun 2006, data rasio tahun 2005 untuk kondisi *financial distress* tahun 2007, dan data rasio tahun 2006 untuk kondisi *financial distress* tahun 2008.

d.2 Pemodelan *Financial Distress* dengan Analisis Diskriminan Linier Secara Univariat

Selain dengan memodelkan secara serentak, model prediksi *financial distress* juga dapat dilakukan secara univariat. Hal ini dilakukan dengan memodelkan kondisi *financial distress* bank umum berdasarkan satu variabel prediktor. Sama halnya dengan pemodelan secara serentak,

data dibagi kedalam data *training* dan data *testing*. Model yang dihasilkan untuk *size* 0 terangkum pada Tabel 4.6.

Tabel 4.6 Model Prediksi *Financial Distress* dengan Analisis Diskriminan Linier Secara Univariat Pada *Size* 0

Variabel	Model	Signifikansi
LDR	$\hat{y} = 0,0022490x_1$	Signifikan
ROA	$\hat{y} = 0,1072892x_2$	Signifikan
ROE	$\hat{y} = 0,0226499x_3$	Signifikan
NIM	$\hat{y} = 0,1476024x_4$	Signifikan
BOPO	$\hat{y} = 0,0200300x_5$	Signifikan
Aktiva Produktif Bermasalah	$\hat{y} = 0,1495763x_6$	Signifikan
NPL	$\hat{y} = 0,0942808x_7$	Signifikan
PPAP Terhadap Aktiva Produktif	$\hat{y} = 0,1697901x_8$	Signifikan
Pemenuhan PPAP	$\hat{y} = 0,0150542x_9$	Signifikan
CAR	$\hat{y} = 0,0264752x_{10}$	Signifikan
ATTM	$\hat{y} = 0,0236866x_{11}$	Signifikan
Inflasi	$\hat{y} = 0,2377038M_1$	Signifikan
Pertumbuhan Ekonomi	$\hat{y} = 2,3314730M_2$	Signifikan

Setelah didapatkan estimasi parameter untuk masing-masing parameter, dilakukan uji signifikansi parameter. Hasil dari uji signifikansi parameter menunjukkan bahwa secara parsial, ketigabelas variabel berpengaruh secara signifikan terhadap kondisi *financial distress* bank umum. Pada data *training* dan data *testing* dengan *window size* 0 menghasilkan nilai akurasi dan AUC sebagaimana tercantum pada Tabel 4.7.

Tabel 4.7 Tabel Ketepatan Klasifikasi Analisis Diskriminan Linier Univariat Pada *Size* 0

	<i>Training</i>		<i>Testing</i>	
	Akurasi	AUC	Akurasi	AUC
LDR	0,9946	0,5000	0,9892	0,5000
ROA	0,9946	0,7486	0,9892	0,7473
ROE	0,9973	0,7500	0,9946	0,7500
NIM	0,9946	0,7486	0,9946	0,7500
BOPO	0,9973	0,7500	0,9892	0,7473
Aktiva Produktif Bermasalah	0,9891	0,7459	0,9946	0,7500
NPL	0,9809	0,7418	0,9892	0,7473
PPAP Terhadap Aktiva Produktif Pemenuhan PPAP	0,9891	0,7459	0,9956	0,7500
CAR	0,9956	0,5000	0,9892	0,5000
ATTM	0,9956	0,5000	0,9892	0,5000
Inflasi	0,9956	0,5000	0,9892	0,5000
Pertumbuhan Ekonomi	0,9956	0,5000	0,9892	0,5000

Mayoritas variabel menghasilkan nilai AUC berkisar antara nilai 0,5 hingga 0,75. Klasifikasi dengan nilai AUC ini dinilai masih kurang baik. Kesalahan klasifikasi yang sering terjadi adalah bank dengan kondisi *financial distress* diklasifikasikan sebagai bank sehat dengan menggunakan model univariat yang telah terbentuk. Model prediksi *financial distress* bank umum juga dibentuk dari data *training* pada *window size* sebesar 1. Model yang terbentuk tertera pada Tabel 4.8.

Tabel 4.8 Model Prediksi *Financial Distress* dengan Analisis Diskriminan Linier Secara Univariat Pada *Size* 1

Variabel	Model	Signifikansi
LDR	$\hat{y} = 0,0022643x_1$	Signifikan
ROA	$\hat{y} = 0,0728720x_2$	Signifikan
ROE	$\hat{y} = 0,0300457x_3$	Signifikan
NIM	$\hat{y} = 0,1476944x_4$	Signifikan
BOPO	$\hat{y} = 0,0275217x_5$	Signifikan

Tabel 4.8 Model Prediksi *Financial Distress* dengan Analisis Diskriminan Linier Secara Univariat Pada *Size 1* (Lanjutan)

Variabel	Model	Signifikansi
Aktiva Produktif Bermasalah	$\hat{y} = 0,1510625x_6$	Signifikan
NPL	$\hat{y} = 0,0900079x_7$	Signifikan
PPAP Terhadap Aktiva Produktif	$\hat{y} = 0,1865752x_8$	Signifikan
Pemenuhan PPAP	$\hat{y} = 0,0152982x_9$	Signifikan
CAR	$\hat{y} = 0,0267638x_{10}$	Signifikan
ATTM	$\hat{y} = 0,0253828x_{11}$	Signifikan
Inflasi	$\hat{y} = 0,2203672M_1$	Signifikan
Pertumbuhan Ekonomi	$\hat{y} = 2,3439520M_2$	Signifikan

Model dari data *training* pada *window size 1* digunakan untuk mengklasifikasikan bank umum di Indonesia. Nilai akurasi dan AUC dari data *training* dan data *testing* untuk masing-masing variabel terangkum pada Tabel 4.9.

Tabel 4.9 Tabel Ketepatan Klasifikasi Analisis Diskriminan Linier Univariat Pada *Size 1*

	<i>Training</i>		<i>Testing</i>	
	Akurasi	AUC	Akurasi	AUC
LDR	0,9932	0,5000	0,9865	0,5000
ROA	0,9864	0,4966	0,9865	0,5000
ROE	0,9830	0,7449	0,9729	0,7432
NIM	0,9932	0,7500	0,9865	0,7500
BOPO	0,9864	0,7466	0,9797	0,7466
Aktiva Produktif Bermasalah	0,9864	0,4966	0,9797	0,4955
NPL	0,9898	0,7466	0,9865	0,7466
PPAP Terhadap Aktiva Produktif	0,9932	0,5000	0,9865	0,5000
Pemenuhan PPAP	0,9932	0,5000	0,9865	0,5000
CAR	0,9932	0,5000	0,9865	0,5000
ATTM	0,9932	0,5000	0,9797	0,4966
Inflasi	0,9932	0,5000	0,9865	0,5000
Pertumbuhan Ekonomi	0,9932	0,5000	0,9865	0,5000

Klasifikasi bank umum dengan menggunakan metode analisis diskriminan secara univariat pada *window size* 1 menunjukkan hasil yang hampir serupa dengan hasil klasifikasi pada *window size* 0. Hasil AUC yang mengukur ketepatan klasifikasi yang didapatkan berkisar antara nilai 0,5 hingga 0,75. Langkah selanjutnya yaitu memodelkan data *training* pada *window size* 2 dengan metode analisis diskriminan secara univariat. Model yang didapatkan untuk masing-masing variabel tercantum pada Tabel 4.10.

Tabel 4.10 Model Prediksi *Financial Distress* dengan Analisis Diskriminan Linier Secara Univariat Pada *Size* 2

Variabel	Model	Signifikansi
LDR	$\hat{y} = 0.0018516x_1$	Signifikan
ROA	$\hat{y} = 0.063583x_2$	Signifikan
ROE	$\hat{y} = 0.0295433x_3$	Signifikan
NIM	$\hat{y} = 0.1441031x_4$	Signifikan
BOPO	$\hat{y} = 0.0282271x_5$	Signifikan
Aktiva Produktif Bermasalah	$\hat{y} = 0.1353861x_6$	Signifikan
NPL	$\hat{y} = 0.0805784x_7$	Signifikan
PPAP Terhadap Aktiva Produktif	$\hat{y} = 0.1397877x_8$	Signifikan
Pemenuhan PPAP	$\hat{y} = 0.0132741x_9$	Signifikan
CAR	$\hat{y} = 0.0229059x_{10}$	Signifikan
ATTM	$\hat{y} = 0.0252074x_{11}$	Signifikan
Inflasi	$\hat{y} = 0.1996427M_1$	Signifikan
Pertumbuhan Ekonomi	$\hat{y} = 3.984982M_2$	Signifikan

Nilai AUC dan akurasi untuk data *training* dan data *testing* pada *window size* 2 akan menunjukkan seberapa baik model yang terbentuk dalam meklasifikasikan dan memprediksi kondisi bank umum di Indonesia. Hasil dari nilai ketepatan klasifikasi tersebut tercantum pada Tabel 4.11.

Tabel 4.11 Ketepatan Klasifikasi Analisis Diskriminan Linier Univariat Pada *Size 2*

	<i>Training</i>		<i>Testing</i>	
	Akurasi	AUC	Akurasi	AUC
LDR	0,9909	0,5000	0,9821	0,5000
ROA	0,9818	0,4954	0,9821	0,5000
ROE	0,9818	0,7431	0,9911	0,7500
NIM	0,9909	0,5000	0,9821	0,5000
BOPO	0,9864	0,7454	0,9911	0,7500
Aktiva Produktif Bermasalah	0,9864	0,4977	0,9821	0,5000
NPL	0,9818	0,4954	0,9821	0,5000
PPAP Terhadap Aktiva Produktif	0,9909	0,5000	0,9821	0,5000
Pemenuhan PPAP	0,9909	0,5000	0,9821	0,5000
CAR	0,9909	0,5000	0,9821	0,5000
ATTM	0,9864	0,4977	0,9732	0,4955
Inflasi	0,9909	0,5000	0,9821	0,5000
Pertumbuhan Ekonomi	0,9909	0,5000	0,9821	0,5000

Hasil nilai ketepatan klasifikasi pada data *training* dan data *testing* pada *window size 2* tidak memiliki perbedaan yang signifikan dengan nilai ketepatan klasifikasi data *training* dan data *testing* pada *window size* ukuran 0 dan 1. AUC yang bernilai dibawah 80% menunjukkan bahwa klasifikasi yang dihasilkan masih belum cukup baik. Selain dari *window size* dengan ukuran 0, 1, dan 2, *window size* ukuran 3 juga dimodelkan secara univariat. Tabel 4.12 menunjukkan model yang terbentuk melalui analisis diskriminan univariat pada data *training* untuk *window size 3*.

Tabel 4.12 Model Prediksi *Financial Distress* dengan Analisis Diskriminan Linier Secara Univariat Pada *Size 3*

Variabel	Model	Signifikansi
LDR	$\hat{y} = 0,0016586x_1$	Signifikan
ROA	$\hat{y} = 0,1005435x_2$	Signifikan
ROE	$\hat{y} = 0,0343889x_3$	Signifikan
NIM	$\hat{y} = 0,1371899x_4$	Signifikan
BOPO	$\hat{y} = 0,0283686x_5$	Signifikan
Aktiva Produktif Bermasalah	$\hat{y} = 0,1222319x_6$	Signifikan
NPL	$\hat{y} = 0,0744508x_7$	Signifikan
PPAP Terhadap Aktiva Produktif	$\hat{y} = 0,1198812x_8$	Signifikan
Pemenuhan PPAP	$\hat{y} = 0,0115879x_9$	Signifikan
CAR	$\hat{y} = 0,0206489x_{10}$	Signifikan
ATTM	$\hat{y} = 0,0244305x_{11}$	Signifikan
Inflasi	$\hat{y} = 0,1874964M_1$	Signifikan
Pertumbuhan Ekonomi	$\hat{y} = 3,3468110M_2$	Signifikan

Nilai pada data *testing* kemudian dimasukkan pada model dari data *training* sehingga didapatkan klasifikasi baru pada masing-masing bank. Evaluasi terhadap metode klasifikasi kemudian dilakukan untuk mengukur ketepatan klasifikasi. Nilai AUC dan akurasi dari data *training* dan data *testing* pada *window size 3* tercantum pada Tabel 4.13.

Tabel 4.13 Tabel Ketepatan Klasifikasi Analisis Diskriminan Linier Univariat Pada *Size 3*

	<i>Training</i>		<i>Testing</i>	
	Akurasi	AUC	Akurasi	AUC
LDR	0,9864	0,5000	0,9733	0,5000
ROA	0,9932	0,7500	0,9733	0,7432
ROE	0,9864	0,7466	0,9733	0,7432
NIM	0,9864	0,5000	0,9733	0,5000
BOPO	0,9932	0,7500	0,9733	0,7432
Aktiva Produktif Bermasalah	0,9864	0,5000	0,9733	0,5000
NPL	0,9796	0,4966	0,9733	0,5000

Tabel 4.13 Tabel Ketepatan Klasifikasi Analisis Diskriminan Linier Univariat Pada *Size* 3 (Lanjutan)

	<i>Training</i>		<i>Testing</i>	
	Akurasi	AUC	Akurasi	AUC
PPAP Terhadap Aktiva Produktif	0,9864	0,5000	0,9733	0,5000
Pemenuhan PPAP	0,9864	0,5000	0,9733	0,5000
CAR	0,9864	0,5000	0,9733	0,5000
ATM	0,9864	0,5000	0,9733	0,5000
Inflasi	0,9864	0,5000	0,9733	0,5000
Pertumbuhan Ekonomi	0,9864	0,5000	0,9733	0,5000

Secara umum, baik pada *window size* 0,1,2 maupaun 3 memberikan hasil yang tidak berbeda secara signifikan. Nilai AUC yang berada dibawah 80% menunjukkan bahwa metode analisis diskriminan yang dilakukan secara parsial terhadap masing-masing variabel belum memberikan hasil yang baik. Namun, seluruh variabel menunjukkan hasil bahwa seluruh variabel memiliki pengaruh yang signifikan terhadap kondisi *financial distress* bank umum di Indonesia. Kesalahan klasifikasi yang dihasilkan juga serupa untuk setiap *size*. Kesalahan terjadi pada bank dengan *financial distress* yang diklasifikasikan sebagai bank sehat.

d.3 *Pemodelan Financial Distress dengan Analisis Diskriminan Linier Menggunakan Stepwise*

Feature selection merupakan salah satu alternatif yang dapat digunakan untuk mengetahui variabel yang secara signifikan berpengaruh terhadap kondisi *financial distress* bank umum. Pada sub bab sebelumnya, terlihat bahwa terdapat beberapa variabel yang memiliki korelasi yang cukup tinggi. Hal ini mengindikasikan adanya multikolinieritas. Rasio keuangan menggunakan suatu nilai tertentu untuk mendapatkan beberapa nilai rasio keuangan. Maka, *stepwise* dilakukan untuk memilah variabel yang secara signifikan mampu meberikan pengaruh terhadap kondisi *financial distress* bank-bank umum di Indonesia. Tabel 4.14 merupakan

variabel yang diikutkan dalam analisis setelah dilakukan *feature selection*.

Tabel 4.14 Variabel Terpilih Pada Analisis Diskriminan Linier

<i>Size</i>	Variabel	<i>Step</i>
0	BOPO	4
	ATTM	
	ROA	
	ROE	
1	ROA	3
	ROE	
2	BOPO	3
	ROA	
	ROE	
3	ROA	1

Stepwise menghasilkan variabel-variabel yang berpengaruh signifikan pada kondisi *financial distress*. Setelah variabel-variabel tersebut didapatkan, maka variabel-variabel terpilih tersebut digunakan untuk memodelkan ulang kondisi *financial distress* yang hanya terdiri dari variabel hasil *stepwise*. Model yang diperoleh dari metode analisis diskriminan linier dengan *stepwise* tercantum pada Tabel 4.15.

Tabel 4.15 Model Prediksi *Financial Distress* pada Analisis Diskriminan Linier dengan *Stepwise*

<i>Size</i>	Model
0	$\hat{y} = 0,0317x_2 - 0,0085x_3 + 0,0169x_5 - 0,0070x_{11}$
1	$\hat{y} = 0,0508x_2 - 0,0247x_3 + 0,0176x_5$
2	$\hat{y} = 0,0575x_2 - 0,0265x_3 + 0,0205x_5$
3	$\hat{y} = 0,1005x_2$

Variabel ROA terpilih pada *size* 0 hingga 3, variabel ROE dan BOPO terpilih pada *size* 0 hingga 2, dan variabel ATTM terpilih pada *size* 0 saja. ROA menggambarkan kemampuan bank dalam menghasilkan profit atau laba. Semakin tinggi nilai ROA maka, semakin baik kemampuan bank menghasilkan keuntungan. Variabel selanjutnya adalah ROE. ROE merupakan rasio keuangan perbankan yang

digunakan untuk mengetahui kemampuan suatu bank untuk mengembalikan modal yang telah ditanamkan. Semakin tinggi nilai ROE maka semakin baik keadaan suatu bank dan semakin kecil kemungkinan bank mengalami *financial distress*. Kemudian variabel selanjutnya yaitu BOPO. Rasio BOPO merupakan perbandingan antara beban operasional bank dengan pendapatan operasional bank. Semakin besar nilai BOPO menandakan bahwa pengeluaran bank untuk kebutuhan operasional lebih banyak dari pendapatannya. Semakin kecil nilai BOPO maka semakin baik keadaan keuangan suatu bank. Variabel yang terakhir yaitu ATTM. Tingginya nilai rasio ATTM mengindikasikan bahwa modal yang dimiliki bank tidaklah cukup untuk menutupi aktiva produktif dan inventaris yang dibutuhkan suatu bank.

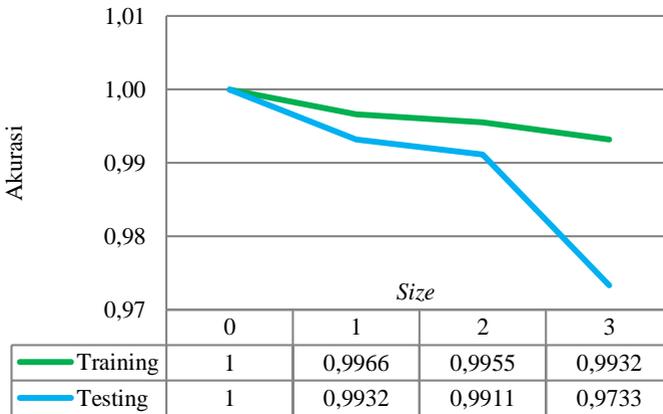
Model pada Tabel 4.15 digunakan untuk memprediksi *financial distress* bank umum pada data *testing*. Nilai AUC dan akurasi digunakan untuk mengukur ketepatan klasifikasi dari model yang terbentuk menggunakan metode analisis diskriminan linier dengan *stepwise*. Tabel 4.16 merupakan nilai-nilai AUC dan akurasi dari data *training* dan data *testing* dari metode analisis diskriminan linier dengan *stepwise*.

Tabel 4.16 Ketepatan Klasifikasi Analisis Diskriminan Linier dengan *Stepwise*

Size	Training		Testing	
	Akurasi	AUC	Akurasi	AUC
0	0,9973	0,7500	0,9892	0,7473
1	0,9932	0,7483	0,9797	0,7432
2	0,9863	0,7454	0,9911	0,7500
3	0,9932	0,7500	0,9733	0,7432

Nilai AUC yang dihasilkan dari metode analisis diskriminan linier dengan *stepwise* tidak berbeda signifikan dengan nilai AUC yang dihasilkan melalui analisis diskriminan secara serentak. Nilai AUC yang bernilai disekitar 75% menunjukkan bahwa klasifikasi bank dengan metode analisis diskriminan linier dengan *stepwise* telah cukup baik. Kesalahan

klasifikasi yang umum terjadi pada kasus ini adalah bank dengan kondisi *financial distress* yang justru diklasifikasikan sebagai bank sehat. Gambar 4.31 menunjukkan perbedaan nilai akurasi dari metode analisis diskriminan linier dengan *stepwise*.



Gambar 4.31 Nilai Akurasi Metode Analisis Diskriminan Linier dengan *Stepwise*

Pada *size 3* terlihat bahwa nilai akurasi data *training* tergolong tinggi, namun nilai akurasi dari data *testing* merupakan nilai terendah dibanding dengan *size* lainnya. Sebaliknya, pada *size 2* akurasi dari data *testing* lebih tinggi dari data *training*. Jika terlihat pada *size 0* menghasilkan nilai akurasi yang baik pada data *training* maupun data *testing*. Namun, *size 0* dianggap kurang memiliki manfaat mengingat publikasi dari rasio keuangan baru didapatkan pada akhir tahun. Maka, *size 2* dianggap paling baik dikarenakan nilai akurasi dari data *training* maupun data *testing* memiliki nilai yang tinggi.

e. **Pemodelan *Financial Distress* dengan Analisis Diskriminan Kernel**

Asumsi distribusi normal multivariat yang seharusnya dipenuhi ternyata tidak dapat terpenuhi. Oleh sebab itu digunakan metode klasifikasi analisis diskriminan kernel yang bebas dari asumsi tersebut. Analisis diskriminan kernel yang digunakan dalam klasifikasi bank dilakukan secara serentak dan dengan menggunakan *stepwise*.

e.1 **Pemodelan *Financial Distress* dengan Analisis Diskriminan Kernel Secara Serentak**

Klasifikasi dilakukan sebanyak empat kali dikarenakan terdapat empat skema *window size*. Data dibagi dalam dua kelompok yaitu data *training* dan data *testing*. Data *training* diambil sebanyak 2/3 jumlah data secara keseluruhan secara acak, sedangkan sisanya dijadikan data *testing*. Hasil dari uji signifikansi parameter yang dilakukan pada model dari metode analisis diskriminan kernel tercantum pada Tabel 4.17.

Tabel 4.17 Variabel yang Berpengaruh Signifikan Pada Metode Analisis Diskriminan Kernel

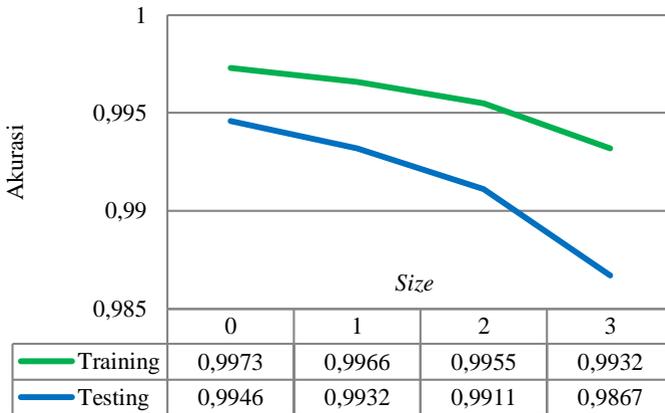
<i>Size</i>	Varibel	Jumlah
0	LDR, ROA, ROE, NIM, BOPO, Aktiva Produktif Bermasalah, NPL, PPAP Terhadap Aktiva Produktif, Pemenuhan PPAP, CAR, ATTM	11
1	LDR, ROE, Aktiva Produktif Bermasalah, PPAP Terhadap Aktiva Produktif	4
2	LDR, Pemenuhan PPAP	2
3	LDR, ROA, ROE, NIM, BOPO, Aktiva Produktif Bermasalah, NPL, ATTM	8

Model yang terbentuk dari data *training* digunakan untuk mengklasifikasikan bank yang terdapat pada data *testing*. Tabel 4.18 merangkum nilai akurasi dan AUC dari data *training* dan data *testing* dari hasil klasifikasi kondisi keuangan bank dengan metode analisis diskriminan kernel.

Tabel 4.18 Ketepatan Klasifikasi Analisis Diskriminan Kernel

Size	Training		Testing	
	Akurasi	AUC	Akurasi	AUC
0	0,9973	0,7500	0,9946	0,7500
1	0,9966	0,7500	0,9932	0,7500
2	0,9955	0,7500	0,9911	0,7500
3	0,9932	0,7500	0,9867	0,7500

Nilai akurasi dan AUC data *training* dan data *testing* dari metode analisis diskriminan kernel tidak memiliki perbedaan yang signifikan untuk setiap *window size*. Perbedaan nilai akurasi dari data *training* dan data *testing* untuk masing-masing *window size* digambarkan pada Gambar 4.32.

**Gambar 4.32** Nilai Akurasi Metode Analisis Diskriminan Kernel Secara Serentak

Gambar 4.32 menunjukkan adanya penurunan nilai akurasi, baik pada data *testing* maupun pada data *training*. *Window size* dengan nilai *size* = 0 memiliki nilai akurasi tertinggi baik pada data *training* maupun pada data *testing*. Meskipun terjadi penurunan seiring dengan penambahan nilai *window size*, namun perubahan yang terjadi tidaklah signifikan. Hal ini juga diperkuat dengan nilai AUC yang sama untuk setiap nilai *window size* baik pada data *training* maupun pada

data *testing*. Baik pada data *training* maupun data *testing* kesalahan klasifikasi yang terjadi adalah bank dengan *financial distress* diklasifikasikan menjadi bank sehat pada metode analisis diskriminan kernel secara serentak.

e.2 Pemodelan *Financial Distress* dengan Analisis Diskriminan Kernel Menggunakan *Stepwise*

Metode lain yang dapat menjadi alternative untuk mendapatkan variabel-variabel yang secara signifikan berpengaruh terhadap kondisi *financial distress* bank umum. Setelah dilakukan langkah-langkah *stepwise* didapatkan variabel-variabel yang berpengaruh pada kondisi bank. Tabel 4.19 menunjukkan variabel-variabel yang terpilih melalui metode *stepwise*.

Tabel 4.19 Variabel Terpilih Pada Analisis Diskriminan Kernel

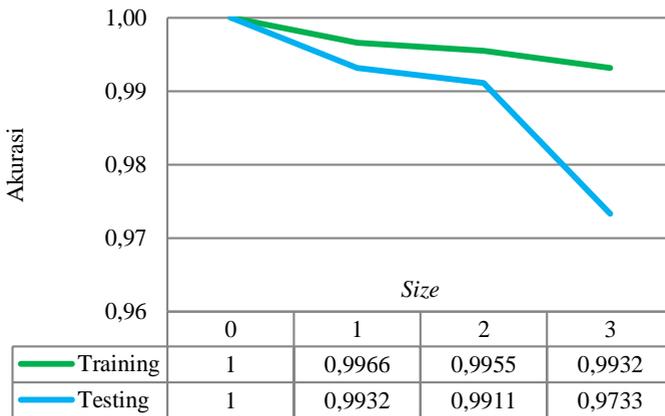
<i>Size</i>	Variabel	<i>Step</i>
0	ROA	11
	ROE	
	BOPO	
1	ROA	11
	ROE	
	BOPO	
2	-	14
3	ROA	12
	BOPO	

Setelah didapatkan variabel terpilih yang berpengaruh signifikan terhadap kondisi *financial distress* bank umum di Indonesia, maka dilakukan pemodelan dengan menggunakan variabel-variabel tersebut. Model yang didapatkan kemudian digunakan untuk memprediksikan kondisi *financial distress* bank umum di Indonesia. Nilai akurasi dan nilai AUC, pada penelitian ini, digunakan untuk mengevaluasi ketepatan klasifikasi kondisi *financial distress* bank umum di Indonesia. Tabel 4.20 menunjukkan nilai akurasi dan AUC dari data *training* dan data *testing*.

Tabel 4.20 Ketepatan Klasifikasi Analisis Diskriminan Kernel Menggunakan *Stepwise*

Size	Training		Testing	
	Akurasi	AUC	Akurasi	AUC
0	1,0000	1,0000	1,0000	1,0000
1	0,9966	0,7500	0,9932	0,7500
2	0,9955	0,7500	0,9911	0,7500
3	0,9932	0,7500	0,9733	0,7432

Nilai akurasi yang dihasilkan metode analisis diskriminan kernel dengan *stepwise* dapat digambarkan kedalam sebuah plot untuk melihat perbedaan nilai akurasi pada masing-masing *size*. Gambar 4.33 menunjukkan perbedaan nilai akurasi dari data *training* dan data *testing* pada masing-masing *size*.



Gambar 4.33 Nilai Akurasi Metode Analisis Diskriminan Kernel dengan *Stepwise*

. Gambar 4.33 menunjukkan bahwa *size* 0 memberikan nilai akurasi yang tertinggi baik pada data *testing* maupun pada data *training*. Tren turun terlihat pada Gambar 4.33. Hal ini ditandai dengan semakin kecilnya nilai akurasi seiring dengan semakin besarnya *size*. Kesalahan yang terjadi pada proses klasifikasi dengan metode analisis diskriminan kernel dengan

stepwise serupa dengan kesalahan klasifikasi yang terjadi pada metode analisis diskriminan kernel secara serentak. Dikarenakan pada *size* 0, informasi didapatkan melalui publikasi akhir tahun, maka tidak memungkinkan menggunakan data pada tahun tersebut untuk memprediksi tahun yang sama. Oleh karena itu, disimpulkan bahwa *size* 1 merupakan *size* yang optimum.

4.5 Pemodelan Prediksi *Financial Distress* dengan Regresi Logistik

Metode kedua yang digunakan untuk memprediksi kondisi *financial distress* bank umum adalah regresi logistik. Data dibagi kedalam data *training* dan data *testing* dengan perbandingan 2/3 dan 1/3. Pemodelan dilakukan sebanyak tiga kali sesuai dengan jumlah *window size*. Sama halnya dengan metode lainnya, metode regresi logistik akan dilakukan secara serentak, secara univariat, dan dengan *stepwise*.

a. Pemodelan *Financial Distress* dengan Regresi Logistik Biner Secara Serentak

Estimasi parameter yang dihasilkan dari metode regresi logistik terlampir pada Lampiran 11. Setelah didapatkan model melalui regresi logistik, dilakukan uji signifikansi parameter. Hasil yang didapatkan menyatakan bahwa baik variabel rasio keuangan bank maupun kondisi perekonomian Indonesia tidak berpengaruh secara signifikan dalam menentukan kondisi *financial distress* pada bank umum di Indonesia. Tidak adanya variabel prediktor yang berpengaruh signifikan terhadap variabel respon kemungkinan disebabkan oleh adanya multikolinieritas yang ditandai dengan besarnya nilai korelasi. Model yang terbentuk dari metode regresi logistik untuk masing-masing *size* tertera pada Tabel 4.21.

Tabel 4.21 Model Prediksi *Financial Distress* dengan Regresi Logistik Biner Secara Serentak

Size	Model
0	$g(x) = -0,0117 + 0,0046x_1 + 1,0600x_2$ $+ 0,3000x_3 + 0,0245x_4 + 0,4530x_5$ $+ 0,5280x_6 + 0,0563x_7 - 2,1500x_8$ $- 0,0089x_9 + 0,0287x_{10} - 0,1940x_{11}$ $+ 0,3180M_1 + 0,9210M_2$
1	$g(x) = -0,0312 + 0,0127x_1 + 0,4830x_2$ $- 0,4810x_3 + 0,4090x_4 - 0,2500x_5$ $- 9,3000x_6 + 6,3300x_7 - 9,7600x_8$ $+ 0,0711x_9 - 0,3350x_{10} + 0,0434x_{11}$ $+ 1,1500M_1 + 53,3000M_2$
2	$g(x) = -0,01990 + 0,0062x_1 + 2,2200x_2$ $+ 0,1680x_3 - 0,8180x_4 + 0,6790x_5$ $- 2,0600x_6 + 1,7400x_7 - 2,6200x_8$ $+ 0,0673x_9 - 0,1050x_{10} + 0,0341x_{11}$ $- 0,4640M_1 + 7,6000M_2$
3	$g(x) = -0,2570 + 0,0089x_1 + 0,0228x_2$ $+ 0,0932x_3 - 2,1800x_4 + 0,3900x_5$ $+ 3,5600x_6 - 0,5900x_7 - 4,1800x_8$ $- 0,3110x_9 + 0,0839x_{10} - 0,2930x_{11}$ $+ 1,7500M_1$

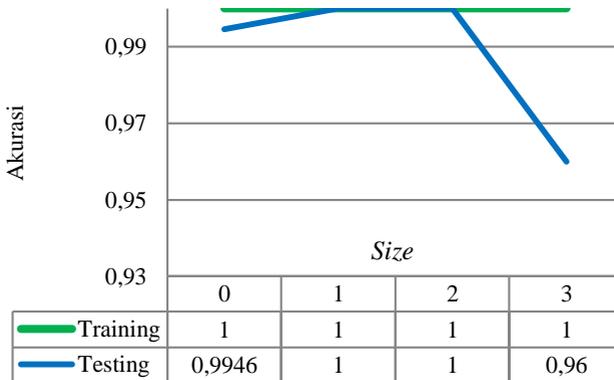
Seluruh variabel tetap digunakan tanpa mengabaikan signifikansi parameter. Model pada Tabel 4.21 digunakan untuk mengklasifikasikan bank umum di Indonesia. Tabel 4.22 menunjukkan nilai-nilai ketepatan klasifikasi pada metode regresi logistik biner untuk seluruh *window size*.

Tabel 4.22 Ketepatan Klasifikasi Regresi Logistik Biner Secara Serentak

Size	Training		Testing	
	Akurasi	AUC	Akurasi	AUC
0	1	1	0,9946	0,9973
1	1	1	1	1
2	1	1	1	1
3	1	1	0,9600	0,9795

Hasil dari perhitungan ketepatan klasifikasi pada data *training* menunjukkan hasil yang sama untuk setiap *window*

size, sedangkan pada data *testing* nilai akurasi dan AUC berfluktuasi. Tingginya nilai akurasi dan nilai AUC menunjukkan bahwa model yang terbentuk untuk memprediksi kondisi *financial distress* bank umum di Indonesia sudah sangat baik. Nilai AUC yang bernilai lebih dari 0,90 pada setiap *window size* termasuk kategori *excellent classification*. Berbeda dengan metode analisis diskriminan, kesalahan klasifikasi yang dihasilkan metode regresi logistik adalah bank sehat diklasifikasikan menjadi bank dengan kondisi *financial distress*. Perbedaan nilai akurasi pada data *training* dan data *testing* digambarkan pada Gambar 4.34.



Gambar 4.34 Nilai Akurasi Metode Regresi Logistik Biner

Nilai akurasi data *training* terlihat sama untuk seluruh nilai *window size* yaitu sebesar 1, sedangkan untuk data *testing* nilai akurasi tertinggi berada pada *window size* 1 dan *window size* 2. Nilai akurasi ini dinilai telah sangat baik untuk mengklasifikasikan kondisi apakah bank merupakan bank sehat atau bank dengan kondisi *financial distress*.

b. Pemodelan *Financial Distress* dengan Regresi Logistik Biner Secara Univariat

Model serentak yang tidak menghasilkan variabel yang signifikan mengindikasikan bahwa terjadi multikolinieritas. Hal ini dikarenakan nilai AUC yang tinggi namun model tidak

signifikan. Salah satu cara untuk melihat variabel yang secara signifikan berpengaruh terhadap kondisi *financial distress* adalah dengan melakukan regresi logistik biner secara univariat. Model yang dihasilkan melalui regresi logistik biner secara multivariat untuk data pada *size* 0 tercantum pada Tabel 4.23.

Tabel 4.23 Model Prediksi *Financial Distress* dengan Regresi Logistik Biner Secara Univariat Pada *Size* 0

Variabel	Model	Signifikansi
LDR	$g(x) = -4,9862 - 0,0014x_1$	Tidak
ROA	$g(x) = -5,3296 - 0,0346x_2$	Signifikan
ROE	$g(x) = -6,2339 - 0,0235x_3$	Signifikan
NIM	$g(x) = -2,8101 - 0,3467x_4$	Signifikan
BOPO	$g(x) = -13,5153 + 0,0298x_5$	Signifikan
Aktiva Produktif Bermasalah	$g(x) = -6,4138 + 0,0859x_6$	Signifikan
NPL	$g(x) = -5,9192 + 0,0426x_7$	Signifikan
PPAP Terhadap Aktiva Produktif	$g(x) = -5,9534 + 0,0737x_8$	Signifikan
Pemenuhan PPAP	$g(x) = -0,1131 - 0,0232x_9$	Tidak
CAR	$g(x) = -2,2839 - 0,0876x_{10}$	Signifikan
ATTM	$g(x) = -5,0385 - 0,0035x_{11}$	Tidak
Inflasi	$g(x) = -5,9772 + 0,0749M_1$	Tidak
Pertumbuhan Ekonomi	$g(x) = -21,316 + 2,713M_2$	Tidak

Hasil uji signifikansi parameter menunjukkan bahwa terdapat delapan variabel yang berpengaruh signifikan terhadap kondisi bank dan lima variabel lainnya tidak berpengaruh signifikan terhadap kondisi bank. Lima variabel yang menunjukkan hasil tidak signifikan adalah LDR, pemenuhan PPAP, ATTM, inflasi, dan pertumbuhan ekonomi. Berdasarkan hasil analisis diketahui bahwa kondisi makroekonomi, yang pada penelitian ini diwakilkan oleh inflasi dan pertumbuhan ekonomi, tidak berpengaruh signifikan terhadap kondisi suatu bank. LDR merupakan salah satu rasio yang termasuk dalam rasio likuiditas bank. Rasio ini

menggambarkan apakah bank termasuk kedalam bank yang likuid atau tidak. Rasio ATTM termasuk dalam rasio kecukupan modal dan rasio pemenuhan PPAP termasuk dalam rasio aktiva produktif. Model yang terbentuk kemudian digunakan untuk mengklasifikasikan bank dalam data *training* dan data *testing*. Nilai AUC dan akurasi yang didapatkan tercantum pada Tabel 4.24.

Tabel 4.24 Ketepatan Klasifikasi Regresi Logistik Biner Univariat Pada *Size 0*

	<i>Training</i>		<i>Testing</i>	
	Akurasi	AUC	Akurasi	AUC
LDR	0,9909	0,5000	0,9821	0,5000
ROA	0,9818	0,4954	0,9821	0,5000
ROE	0,9818	0,7431	0,9911	0,7500
NIM	0,9909	0,5000	0,9821	0,5000
BOPO	0,9864	0,7454	0,9911	0,7500
Aktiva Produktif Bermasalah	0,9864	0,4977	0,9821	0,5000
NPL	0,9818	0,4954	0,9821	0,5000
PPAP Terhadap Aktiva Produktif	0,9909	0,5000	0,9821	0,5000
Pemenuhan PPAP	0,9909	0,5000	0,9821	0,5000
CAR	0,9909	0,5000	0,9821	0,5000
ATTM	0,9864	0,4977	0,9732	0,4955
Inflasi	0,9909	0,5000	0,9821	0,5000
Pertumbuhan Ekonomi	0,9909	0,5000	0,9821	0,5000

Nilai akurasi yang dihasilkan oleh model berada di atas angka 90%. Hal ini menunjukkan bahwa model telah akurat dalam memprediksi kondisi bank. Namun nilai AUC yang dihasilkan menunjukkan hasil yang berbeda. Nilai AUC yang berkisar antara 50% hingga 75% menunjukkan bahwa klasifikasi yang dihasilkan masih belum cukup baik. Tabel 4.25 menunjukkan model yang terbentuk dari data *training* untuk *window size 1*.

Tabel 4.25 Model Prediksi *Financial Distress* dengan Regresi Logistik Biner Secara Univariat Pada *Size 1*

Variabel	Model	Signifikansi
LDR	$g(x) = -3,6062 - 0,0109x_1$	Tidak
ROA	$g(x) = -4,9917 - 0,0183x_2$	Tidak
ROE	$g(x) = -5,2368 - 0,0231x_3$	Signifikan
NIM	$g(x) = -1,7709 - 0,4430x_4$	Signifikan
BOPO	$g(x) = -10,2165 + 0,0257x_5$	Signifikan
Aktiva Produktif Bermasalah	$g(x) = -5,3847 + 0,04968x_6$	Tidak
NPL	$g(x) = -5,5026 + 0,0349x_7$	Signifikan
PPAP Terhadap Aktiva Produktif	$g(x) = -4,6286 - 0,0932x_8$	Tidak
Pemenuhan PPAP	$g(x) = -3,7831 - 0,0052x_9$	Tidak
CAR	$g(x) = -3,6607 - 0,03172x_{10}$	Tidak
ATTM	$g(x) = -5,8215 + 0,0127x_{11}$	Tidak
Inflasi	$g(x) = -2,2131 - 0,3823M_1$	Tidak
Pertumbuhan Ekonomi	$g(x) = -143,36 + 22,19M_2$	Tidak

Berdasarkan hasil uji signifikansi yang dilakukan, didapatkan hasil bahwa terdapat empat variabel yang berpengaruh signifikan terhadap kondisi bank. Variabel yang dimaksud adalah ROE, NIM, BOPO, dan NPL. Rasio keuangan ROE, NIM, dan BOPO tergabung dalam satu kelompok rasio yaitu rasio rentabilitas bank. Rasio rentabilitas bank menggambarkan kemampuan bank dalam menghasilkan profit melalui kegiatan operasional usaha. Rasio NPL tergabung dalam rasio aktiva produktif yang menggambarkan kredit macet yang terjadi dalam suatu bank. Model kemudian digunakan untuk mengklasifikasikan bank pada data *training* dan data *testing*. Tabel 4.26 merangkum nilai AUC dan akurasi dari data *training* dan juga data *testing*.

Tabel 4.26 Ketepatan Klasifikasi Regresi Logistik Biner Univariat Pada *Size 1*

	<i>Training</i>		<i>Testing</i>	
	Akurasi	AUC	Akurasi	AUC
LDR	0,9932	0,5000	0,9865	0,5000
ROA	0,9932	0,5000	0,9865	0,5000
ROE	0,9966	0,7500	0,9932	0,7500
NIM	0,9966	0,7500	0,9932	0,7500
BOPO	0,9966	0,7500	0,9932	0,7500
Aktiva Produktif Bermasalah	0,9932	0,5000	0,9865	0,5000
NPL	0,9932	0,5000	0,9865	0,5000
PPAP Terhadap Aktiva Produktif	0,9932	0,5000	0,9865	0,5000
Pemenuhan PPAP	0,9932	0,5000	0,9865	0,5000
CAR	0,9932	0,5000	0,9865	0,5000
ATTM	0,9932	0,5000	0,9865	0,5000
Inflasi	0,9932	0,5000	0,9865	0,5000
Pertumbuhan Ekonomi	0,9932	0,5000	0,9865	0,5000

Mayoritas variabel hanya menghasilkan nilai AUC sebesar 50%. Nilai AUC 50% masih dianggap kurang baik untuk memprediksi kondisi *financial distress* pada bank di Indonesia. Hanya terdapat tiga variabel menghasilkan nilai AUC cukup baik, yaitu rasio ROE, NIM, dan BOPO. Kemudian hal yang sama dilakukan untuk data dengan *window size 2*. Tabel 4.27 merangkum model yang terbentuk dari masing-masing variabel pada data *training* untuk *size 2*.

Tabel 4.27 Model Prediksi *Financial Distress* dengan Regresi Logistik Biner Secara Univariat Pada *Size 2*

Variabel	Model	Signifikansi
LDR	$g(x) = -2,6073 - 0,0166x_1$	Tidak
ROA	$g(x) = -4,6786 - 0,0137x_2$	Tidak
ROE	$g(x) = -4,7245 - 0,0234x_3$	Signifikan
NIM	$g(x) = 0,4086 - 0,9693x_4$	Tidak
BOPO	$g(x) = -10,9443 + 0,0319x_5$	Signifikan
Aktiva Produktif Bermasalah	$g(x) = -5,0570 + 0,0437x_6$	Tidak
NPL	$g(x) = -5,1015 + 0,0286x_7$	Tidak
PPAP Terhadap Aktiva Produktif	$g(x) = -3,5111 - 0,3294x_8$	Tidak
Pemenuhan PPAP	$g(x) = -3,3971 - 0,0055x_9$	Tidak
CAR	$g(x) = 0,1748 - 0,1519x_{10}$	Tidak
ATTM	$g(x) = -5,5825 + 0,0136x_{11}$	Tidak
Inflasi	$g(x) = -1,89 - 0,3699M_1$	Tidak
Pertumbuhan Ekonomi	$g(x) = -11,186 + 1,188M_2$	Tidak

Skema *window size 2* menghasilkan dua variabel yang signifikan secara univariat terhadap kondisi suatu bank. Variabel yang dimaksud adalah ROE dan BOPO. ROE dan BOPO termasuk kedalam rasio rentabilitas. Fungsi dari rasio rentabilitas adalah untuk memberikan gambaran terkait kemampuan suatu bank untuk menghasilkan laba dari operasional usahanya. Model pada Tabel 4.27 kemudian digunakan untuk mengklasifikasikan bank umum, apakah bank tersebut termasuk dalam kategori bank sehat atau bank dengan permasalahan keuangan. Nilai AUC dan akurasi yang dihasilkan pada skema *window size 2* dirangkum kedalam Tabel 4.28.

Tabel 4.28 Ketepatan Klasifikasi Regresi Logistik Biner Univariat Pada *Size 2*

	<i>Training</i>		<i>Testing</i>	
	Akurasi	AUC	Akurasi	AUC
LDR	0,9909	0,5000	0,9821	0,5000
ROA	0,9909	0,5000	0,9821	0,5000
ROE	0,9909	0,5000	0,9821	0,5000
NIM	0,9955	0,7500	0,9911	0,7500
BOPO	0,9909	0,5000	0,9821	0,5000
Aktiva Produktif Bermasalah	0,9909	0,5000	0,9821	0,5000
NPL	0,9909	0,5000	0,9821	0,5000
PPAP Terhadap Aktiva Produktif	0,9909	0,5000	0,9821	0,5000
Pemenuhan PPAP	0,9909	0,5000	0,9821	0,5000
CAR	0,9909	0,5000	0,9821	0,5000
ATTM	0,9909	0,5000	0,9821	0,5000
Inflasi	0,9909	0,5000	0,9821	0,5000
Pertumbuhan Ekonomi	0,9909	0,5000	0,9821	0,5000

Dua belas variabel data *training* dan data *testing* menghasilkan nilai AUC sebesar 50%. Nilai AUC yang rendah menunjukkan bahwa model belum dapat mengklasifikasikan kondisi bank umum di Indonesia dengan baik. Hal serupa akan dilakukan terhadap skema *window size 3*. Tabel 4.29 menunjukkan model yang terbentuk dari data *training* pada skema *window size 3*.

Tabel 4.29 Model Prediksi *Financial Distress* dengan Regresi Logistik Biner Secara Univariat Pada *Size 3*

Variabel	Model	Signifikansi
LDR	$g(x) = -1,4507 - 0,0234x_1$	Tidak
ROA	$g(x) = -3,7509 - 0,3310x_2$	Tidak
ROE	$g(x) = -4,1876 - 0,0297x_3$	Signifikan
NIM	$g(x) = 78,96 - 23,68x_4$	Tidak
BOPO	$g(x) = -13,0987 + 0,0463x_5$	Signifikan
Aktiva Produktif Bermasalah	$g(x) = -4,3989 + 0,0179x_6$	Tidak
NPL	$g(x) = -4,4947 + 0,0179x_7$	Tidak
PPAP Terhadap Aktiva Produktif	$g(x) = -3,2727 - 0,2602x_8$	Tidak
Pemenuhan PPAP	$g(x) = -0,5013 - 0,0167x_9$	Tidak
CAR	$g(x) = -3,4513 - 0,0202x_{10}$	Tidak
ATTM	$g(x) = -4,4026 + 0,0023x_{11}$	Tidak
Inflasi	$g(x) = -24,269 + 1,204M_1$	Tidak
Pertumbuhan Ekonomi	$g(x) = -126,13 + 21,48M_2$	Tidak

Skema *window size 3* menghasilkan dua variabel yang berpengaruh signifikan terhadap kondisi *financial distress* suatu bank. Variabel yang berpengaruh signifikan pada *window size 2* dan *window size 3* adalah sama yaitu ROE dan BOPO. Kemudian evaluasi model dilakukan dengan menghitung nilai AUC dan akurasi dari data *training* dan data *testing*. Tabel 4.30 merupakan nilai AUC dan akurasi yang dihasilkan data *training* dan data *testing* pada skema *window size 3*.

Tabel 4.30 Ketepatan Klasifikasi Regresi Logistik Biner Univariat Pada *Size 3*

	<i>Training</i>		<i>Testing</i>	
	Akurasi	AUC	Akurasi	AUC
LDR	0,9864	0,5000	0,9733	0,5000
ROA	0,9932	0,7500	0,9733	0,7432
ROE	0,9932	0,7500	0,9733	0,7432
NIM	1,0000	1,0000	0,9867	0,9932
BOPO	0,9932	0,7500	0,9733	0,7432
Aktiva Produktif Bermasalah	0,9864	0,5000	0,9733	0,5000
NPL	0,9864	0,5000	0,9733	0,5000
PPAP Terhadap Aktiva Produktif	0,9864	0,5000	0,9733	0,5000
Pemenuhan PPAP	0,9864	0,5000	0,9733	0,5000
CAR	0,9864	0,5000	0,9733	0,5000
ATTM	0,9864	0,5000	0,9733	0,5000
Inflasi	0,9864	0,5000	0,9733	0,5000
Pertumbuhan Ekonomi	0,9864	0,5000	0,9733	0,5000

Mayoritas variabel menghasilkan nilai akurasi sebesar 50% hingga 75%. Namun variabel NIM mampu memberikan nilai akurasi dan AUC diatas 95% walupun variabel NIM tidak berpengaruh signifikan terhadap kondisi *financial distress* bank umum di Indonesia. Kesalahan klasifikasi pada setiap skema *window size* adalah bank-bank yang dinyatakan sebagai bank dengan *financial distress* diklasifikasikan sebagai bank sehat.

Secara keseluruhan, jumlah variabel yang berpengaruh signifikan terhadap kondisi *financial distress* secara univariat masih sangat sedikit. Variabel yang selalu berpengaruh signifikan adalah ROE dan BOPO. ROE merupakan rasio yang menggambarkan kemampuan suatu bank untuk mengembalikan modal yang telah ditanamkan. BOPO ialah rasio antara beban operasional dengan pendapatan operasinya. Semakin tinggi nilai ROE maka semakin kecil kemungkinan suatu bank mengalami kondisi *financial distress*

dan semakin kecil nilai BOPO maka semakin kecil juga peluangnya untuk mengalami kondisi *financial distress*.

c. Pemodelan *Financial Distress* dengan Regresi Logistik Biner Menggunakan *Stepwise*

Selain dengan melakukan regresi logistik secara univariat, *stepwise* juga dapat dilakukan untuk melihat variabel yang secara signifikan berpengaruh terhadap kondisi *financial distress* bank umum di Indonesia. Setelah dilakukan prosedur *stepwise*, didapatkan variabel terpilih yang akan dimodelkan kembali. Tabel 4.31 merupakan variabel terpilih untuk regresi logistik biner pada *size* 0 hingga 3.

Tabel 4.31 Variabel Terpilih Pada Regresi Logistik Biner

<i>Size</i>	Variabel	<i>Step</i>
0	NIM BOPO	12
1	Pertumbuhan Ekonomi PPAP Terhadap Aktiva Produktif NPL	11
2	CAR PPAP Terhadap Aktiva Produktif NPL	11
3	PPAP Terhadap Aktiva Produktif Aktiva Produktif Bermasalah Inflasi BOPO	10

Model baru kemudian dibentuk dengan menggunakan variabel yang telah terpilih melalui prosedur *stepwise*. Tabel 4.32 merupakan model yang terbentuk dari data *training* masing-masing skema *window size*.

Tabel 4.32 Model Prediksi *Financial Distress* dengan Regresi Logistik Biner Menggunakan *Stepwise*

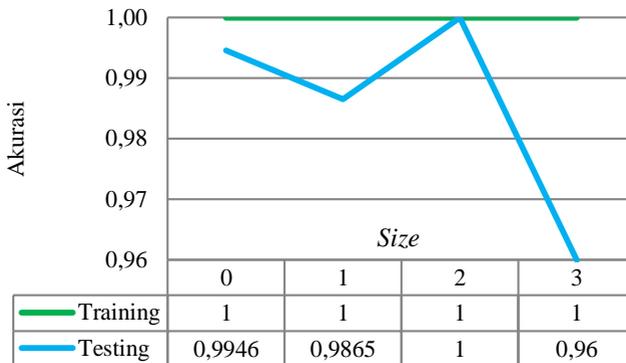
<i>Size</i>	Model
0	$g(x) = -1158,106 - 71,803x_4 + 1,012x_5$
1	$g(x) = -512,262 + 8,211x_7 - 79,299x_8 + 85,674M_2$
2	$g(x) = -87,618 + 9,016x_7 - 69,424x_8 - 4,029x_{10}$
3	$g(x) = -2135,769 + 5,722x_5 + 159,532x_6 - 4,1800 - 438,827x_8 + 69,165M_1$

Model yang terbentuk kemudian digunakan untuk mengklasifikasikan bank umum baik pada data *training* maupun pada data *testing*. Hasil klasifikasi kemudian dievaluasi dengan nilai akurasi dan AUC. Tabel 4.33 menunjukkan nilai ketepatan klasifikasi dari data *training* dan data *testing* pada masing-masing skema *window size*.

Tabel 4.33 Ketepatan Klasifikasi Regresi Logistik Biner dengan *Stepwise*

<i>Size</i>	<i>Training</i>		<i>Testing</i>	
	Akurasi	AUC	Akurasi	AUC
0	1	1	0,9946	0,9973
1	1	1	0,9865	0,9932
2	1	1	1	1
3	1	1	0,9600	0,9795

Hasil dari perhitungan ketepatan klasifikasi pada data *training* menunjukkan hasil yang sama untuk setiap *window size*, sedangkan pada data *testing* nilai akurasi dan AUC berfluktuasi. Kesalahan klasifikasi pada data *testing* adalah bank dengan kondisi normal diklasifikasikan sebagai bank dengan kondisi *financial distress*. Skema *window size* 2 terlihat memberikan nilai ketepatan klasifikasi paling tinggi diantara *window size* lainnya. Ilustrasi perbedaan nilai akurasi dari data *training* dan data *testing* digambarkan pada Gambar 4.35.



Gambar 4.35 Nilai Akurasi Metode Regresi Logistik Biner dengan *Stepwise*

Gambar 4.35 menunjukkan bahwa nilai akurasi data *training* untuk setiap *size* adalah sama. Nilai akurasi untuk data *testing* yang tertinggi adalah pada *size* 2 yaitu sebesar 100%, sedangkan nilai akurasi terendahnya berada pada *size* 3 yaitu sebesar 0,96. Secara keseluruhan nilai akurasi yang dihasilkan oleh data *training* dan data *testing* untuk metode regresi logistik biner dengan *stepwise* sudah cukup baik. Hal ini juga didukung oleh tingginya nilai AUC yang dihasilkan.

4.6 Pemodelan Prediksi *Financial Distress* dengan *Generalized Extreme Value Regression*

Metode ketiga yang digunakan untuk mengklasifikasikan suatu bank termasuk kategori bank sehat atau bank dengan kondisi *financial distress* adalah metode *generalized extreme value regression* (GEVR). Langkah pertama yang dilakukan adalah membagi data kedalam data *training* dan data *testing*. Data training diambil sebanyak $\frac{2}{3}$ dari data keseluruhan secara acak.

a. Pemodelan *Financial Distress* dengan GEVR Secara Serentak

Model didapatkan dengan menggunakan data *training*, setelah didapatkan model dari data *training*, maka model akan digunakan untuk mengklasifikasikan bank. Sebelum dilakukan

pemodelan dengan menggunakan metode GEVR, terlebih dahulu ditentukan nilai parameter τ . Pemilihan nilai parameter τ dilakukan dengan mencobakan 20 nilai yaitu nilai -0,1 hingga 0,1. Dari seluruh nilai didapatkan bahwa $\tau = 0,05$ menghasilkan nilai log likelihood terbesar, namun $\tau = 0,1$ mampu menghasilkan nilai yang lebih baik sehingga pemodelan dilanjutkan dengan nilai $\tau = 0,1$. Tabel 4.34 menunjukkan model dari GEVR.

Tabel 4.34 Model Prediksi *Financial Distress* dengan GEVR Secara Serentak

<i>Size</i>	Model
0	$\hat{z} = -38,3 - 0,0023x_1 - 0,0564x_2 + 0,104x_3$ $- 0,266x_4 + 0,0764x_5 - 0,147x_6 + 0,156x_7$ $- 0,058x_8 - 0,0007x_9 + 0,0401x_{10} + 0,018x_{11}$ $- 0,156M_1 + 2,92M_2$
1	$\hat{z} = -26,114 + 0,0023x_1 + 0,0195x_2 - 0,0116x_3$ $- 0,1415x_4 + 0,004x_5 - 0,436x_6 + 0,305x_7$ $- 0,360x_8 + 0,0063x_9 - 0,0406x_{10}$ $- 0,0017x_{11} - 0,52016M_1 + 4,5514M_2$
2	$\hat{z} = -40,298 - 0,0017x_1 + 0,178x_2 + 0,026x_3$ $- 0,207x_4 + 0,1172x_5 - 0,3876x_6 + 0,2162x_7$ $- 0,06x_8 + 0,013x_9 - 0,007x_{10} + 0,012x_{11}$ $- 0,128M_1 + 2,724M_2$
3	$\hat{z} = -3,063 - 0,0046x_1 + 1,109x_2 - 0,024x_3$ $- 0,41x_4 + 0,1172x_5 + 0,3x_6 + 0,1896x_7$ $- 0,2412x_8 - 0,0209x_9 + 0,0159x_{10}$ $- 0,0262x_{11} + 0,5559M_1 - 3,739M_2$

Estimasi parameter dari metode GEVR dapat dilihat pada Lampiran 15. Tabel 4.35 secara ringkas menunjukkan variabel-variabel yang secara signifikan berpengaruh terhadap kondisi bank.

Tabel 4.35 Variabel yang Berpengaruh Secara Signifikan Pada Metode GEVR

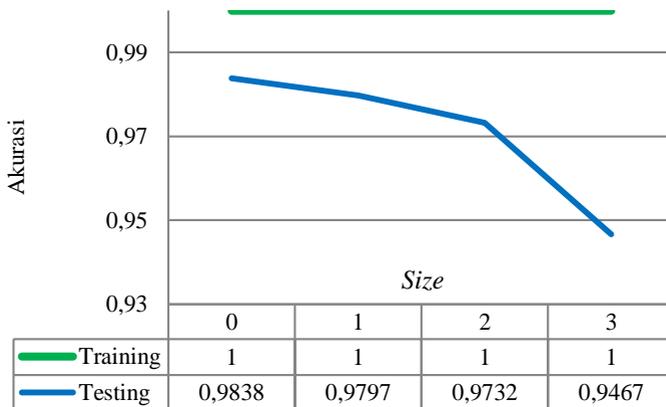
<i>Size</i>	Variabel	Jumlah
0	-	Tidak Ada
1	Aktiva Produktif Bermasalah Pertumbuhan Ekonomi	2
2	-	Tidak Ada
3	BOPO	1

Hasil uji signifikansi parameter menunjukkan bahwa hanya sedikit variabel yang berpengaruh signifikan terhadap kondisi bank. Namun, penelitian ini akan tetap menggunakan seluruh variabel untuk memprediksi apakah bank merupakan bank sehat atau bank tengah mengalami *financial distress*. Hasil klasifikasi dengan menggunakan metode GEVR dinilai baik atau tidak dengan menggunakan nilai akurasi dan AUC. Nilai akurasi dan AUC yang dihasilkan dirangkum pada Tabel 4.36.

Tabel 4.36 Ketepatan Klasifikasi GEVR Secara Serentak

<i>Size</i>	<i>Training</i>		<i>Testing</i>	
	Akurasi	AUC	Akurasi	AUC
0	1	1	0,9838	0,9918
1	1	1	0,9797	0,9897
2	1	1	0,9732	0,9864
3	1	1	0,9467	0,9725

Klasifikasi menghasilkan nilai AUC yang berada diatas nilai 0,9. Hal ini berarti klasifikasi yang dihasilkan oleh GEVR masuk dalam kategori *excellent classification*. Kesalahan klasifikasi yang terjadi adalah bank dengan status sehat diklasifikasikan sebagai bank dengan kondisi *financial distress*. Gambar 4.36 menunjukkan perbedaan nilai akurasi yang dihasilkan dari metode GEVR untuk setiap *window size*.



Gambar 4.36 Nilai Akurasi Metode GEVR

Nilai akurasi dari data *testing* pada metode GEVR terlihat mengalami penurunan, sedangkan akurasi data *testing* tertinggi berada *window size* 0. Berbeda dengan data *testing* yang menghasilkan akurasi yang berbeda-beda, klasifikasi data *training* menghasilkan nilai akurasi yang sama untuk semua *window size* yaitu sebesar 1.

b. Pemodelan *Financial Distress* dengan GEVR Secara Univariat

Masing-masing variabel dimodelkan secara univariat terhadap kondisi bank. Hal ini dilakukan untuk mengetahui variabel apa saja yang secara parsial berpengaruh signifikan terhadap kondisi bank umum di Indonesia. Model untuk data *training* dan data *testing* pada skema *window size* 0 tercantum pada Tabel 4.37.

Tabel 4.37 Model Prediksi *Financial Distress* dengan GEVR Secara Univariat Pada *Size 0*

Variabel	Model	Signifikansi
LDR	$\hat{z} = -4,9862 - 0,0014x_1$	Tidak
ROA	$\hat{z} = -1,5969 - 0,0311x_2$	Tidak
ROE	$\hat{z} = -1,7985 - 0,0088x_3$	Signifikan
NIM	$\hat{z} = -0,5543 - 0,1501x_4$	Signifikan
BOPO	$\hat{z} = -4,4848 + 0,01061x_5$	Tidak
Aktiva Produktif Bermasalah	$\hat{z} = -2,0536 + 0,0383x_6$	Signifikan
NPL	$\hat{z} = -1,9671 + 0,0238x_7$	Signifikan
PPAP Terhadap Aktiva Produktif	$\hat{z} = -5,5398 + 0,1036x_8$	Tidak
Pemenuhan PPAP	$\hat{z} = -0,1658 - 0,0229x_9$	Tidak
CAR	$\hat{z} = -1,2951 - 0,0601x_{10}$	Tidak
ATTM	$\hat{z} = -5,0385 - 0,0035x_{11}$	Tidak
Inflasi	$\hat{z} = -5,977 + 0,0749M_1$	Tidak
Pertumbuhan Ekonomi	$\hat{z} = -4,5989 + 0,5189M_2$	Tidak

Uji signifikansi yang dilakukan pada model untuk masing-masing variabel menunjukkan hasil bahwa terdapat empat variabel yang secara univariat berpengaruh signifikan terhadap kondisi *financial distress* bank di Indonesia. Variabel yang dimaksud adalah ROE, NIM, aktiva produktif bermasalah, dan NPL. Nilai AUC dan akurasi dari ketigabelas model pada Tabel 4.37 terangkum pada Tabel 4.38.

Tabel 4.38 Ketepatan Klasifikasi GEVR Univariat Pada *Size 0*

	<i>Training</i>		<i>Testing</i>	
	Akurasi	AUC	Akurasi	AUC
LDR	0,9946	0,5000	0,9892	0,5000
ROA	0,9918	0,4986	0,9838	0,4973
ROE	0,9946	0,7486	0,9946	0,7500
NIM	0,9946	0,7486	0,9946	0,7500
BOPO	0,9946	0,7486	0,9892	0,7473
Aktiva Produktif Bermasalah	0,9918	0,4986	0,9892	0,5000
NPL	0,9918	0,4986	0,9892	0,5000
PPAP Terhadap Aktiva Produktif	0,9891	0,4973	0,9892	0,5000
Pemenuhan PPAP	0,9946	0,5000	0,9892	0,5000
CAR	0,9918	0,4986	0,9838	0,4973
ATM	0,9946	0,5000	0,9892	0,5000
Inflasi	0,9946	0,5000	0,9892	0,5000
Pertumbuhan Ekonomi	0,9946	0,5000	0,9892	0,5000

Nilai akurasi yang dihasilkan model pada masing-masing variabel telah menunjukkan angka yang tinggi. Namun, nilai AUC yang relatif rendah menunjukkan bahwa model belum baik dalam memprediksikan kondisi *financial distress* bank umum di Indonesia. Pada skema *window size* sebesar 1 dilakukan pemodelan serupa sehingga didapatkan tigabelas model berbeda. Tabel 4.39 menunjukkan model yang terbentuk pada masing-masing variabel.

Tabel 4.39 Model Prediksi *Financial Distress* dengan GEVR Secara Univariat Pada *Size* 1

Variabel	Model	Signifikansi
LDR	$\hat{z} = -1,2589 - 0,0018x_1$	Tidak
ROA	$\hat{z} = -4,7288 - 0,1462x_2$	Tidak
ROE	$\hat{z} = -10,3122 - 0,0527x_3$	Signifikan
NIM	$\hat{z} = -0,4855 - 0,1333x_4$	Signifikan
BOPO	$\hat{z} = -18,8648 + 0,0504x_5$	Signifikan
Aktiva Produktif Bermasalah	$\hat{z} = -5,159 + 0,147x_6$	Tidak
NPL	$\hat{z} = -5,5019 + 0,071x_7$	Tidak
PPAP Terhadap Aktiva Produktif	$\hat{z} = -1,4276 - 0,0148x_8$	Tidak
Pemenuhan PPAP	$\hat{z} = -3,783 - 0,0052x_9$	Tidak
CAR	$\hat{z} = -1,2473 - 0,0056x_{10}$	Tidak
ATTM	$\hat{z} = -5,8214 + 0,0165x_{11}$	Tidak
Inflasi	$\hat{z} = -1,0769 - 0,0551M_1$	Tidak
Pertumbuhan Ekonomi	$\hat{z} = -85,80 + 13,43M_2$	Tidak

Melalui model yang telah didapatkan, dapat dihitung nilai ketepatan klasifikasi dari model tersebut. Klasifikasi dilakukan dengan memasukkan data pada data *training* dan data *testing* untuk skema *window size* 1 kedalam model yang telah terbentuk. Tabel 4.40 menunjukkan nilai akurasi dan AUC dari data *training* dan data *testing*.

Tabel 4.40 Ketepatan Klasifikasi GEVR Secara Univariat Pada *Size* 1

	<i>Training</i>		<i>Testing</i>	
	Akurasi	AUC	Akurasi	AUC
LDR	0,9932	0,5000	0,9865	0,5000
ROA	0,9864	0,4966	0,9865	0,5000
ROE	0,9966	0,7500	0,9932	0,7500
NIM	0,9966	0,7500	0,9932	0,7500
BOPO	0,9966	0,7500	0,9932	0,7500
Aktiva Produktif Bermasalah	0,9898	0,4983	0,9797	0,4966
NPL	0,9898	0,4983	0,9865	0,5000
PPAP Terhadap Aktiva Produktif	0,9932	0,5000	0,9865	0,5000
Pemenuhan PPAP	0,9932	0,5000	0,9865	0,5000
CAR	0,9932	0,5000	0,9865	0,5000
ATTM	0,9932	0,5000	0,9797	0,4966
Inflasi	0,9932	0,5000	0,9865	0,5000
Pertumbuhan Ekonomi	0,9932	0,5000	0,9865	0,5000

Nilai AUC yang dihasilkan dari model univariat pada metode GEVR dengan *window size* 1 hanya berkisar pada nilai 50% hingga 75%. Hal ini menunjukkan bahwa model belum cukup baik untuk mengklasifikasikan apakah bank mengalami *financial distress* atau tidak. Hal serupa dilakukan pada data *training* dan data *testing* untuk skema *window size* 2. Tabel 4.41 menunjukkan model yang terbentuk pada skema *window size* 2.

Tabel 4.41 Model Prediksi *Financial Distress* dengan GEVR Secara Univariat Pada *Size 2*

Variabel	Model	Signifikansi
LDR	$\hat{z} = -1,0986 - 0,0026x_1$	Signifikan
ROA	$\hat{z} = -1,4279 - 0,0053x_2$	Tidak
ROE	$\hat{z} = -10,823 - 0,0650x_3$	Signifikan
NIM	$\hat{z} = 0,5820 - 0,4594x_4$	Signifikan
BOPO	$\hat{z} = -3,8076 + 0,0123x_5$	Signifikan
Aktiva Produktif Bermasalah	$\hat{z} = -5,0557 + 0,0781x_6$	Tidak
NPL	$\hat{z} = -1,6208 + 0,0132x_7$	Tidak
PPAP Terhadap Aktiva Produktif	$\hat{z} = -3,4988 - 0,3073x_8$	Tidak
Pemenuhan PPAP	$\hat{z} = -1,1841 - 0,0011x_9$	Tidak
CAR	$\hat{z} = -0,4803 - 0,0289x_{10}$	Tidak
ATTM	$\hat{z} = -1,7206 + 0,0044x_{11}$	Tidak
Inflasi	$\hat{z} = -0,9788 - 0,0582M_1$	Tidak
Pertumbuhan Ekonomi	$\hat{z} = -2,9026 + 0,2688M_2$	Tidak

Model univariat pada data *training* dengan *window size* 2 menghasilkan empat variabel yang berpengaruh secara signifikan terhadap kondisi keuangan bank. Variabel yang dimaksud adalah LDR, ROE, NIM, dan BOPO. LDR termasuk dalam rasio likuiditas bank sedangkan ROE, NIM, dan BOPO termasuk dalam rasio rentabilitas bank. Tabel 4.42 menunjukkan nilai akurasi dan AUC dari model yang terdapat pada Tabel 4.41.

Tabel 4.42 Ketepatan Klasifikasi GEVR Univariat Pada *Size 2*

	<i>Training</i>		<i>Testing</i>	
	Akurasi	AUC	Akurasi	AUC
LDR	0,9909	0,5000	0,9821	0,5000
ROA	0,9909	0,5000	0,9821	0,5000
ROE	0,9909	0,5000	0,9732	0,4955
NIM	0,9909	0,7500	0,9911	0,7500
BOPO	0,9864	0,4977	0,9821	0,5000
Aktiva Produktif Bermasalah	0,9864	0,4977	0,9821	0,5000
NPL	0,9909	0,5000	0,9821	0,5000
PPAP Terhadap Aktiva Produktif	0,9818	0,4954	0,9821	0,5000
Pemenuhan PPAP	0,9909	0,5000	0,9821	0,5000
CAR	0,9909	0,5000	0,9821	0,5000
ATTM	0,9909	0,5000	0,9821	0,5000
Inflasi	0,9909	0,5000	0,9821	0,5000
Pertumbuhan Ekonomi	0,9909	0,5000	0,9821	0,5000

Nilai AUC yang dihasilkan baik dari data *training* dan data *testing* berkisar pada nilai 50% hingga 75%. Hal ini menunjukkan bahwa model belum cukup baik untuk memprediksi *financial distress*. Hal ini wajar terjadi dikarenakan hanya melibatkan satu variabel saja. Kemudian hal yang sama dilakukan pada skema *window size 3*. Tabel 4.43 menunjukkan model yang terbentuk dari data *training* dengan menggunakan metode GEVR secara univariat.

Tabel 4.43 Model Prediksi *Financial Distress* dengan GEVR Secara Univariat Pada *Size* 3

Variabel	Model	Signifikansi
LDR	$\hat{z} = -1,0149 - 0,0026x_1$	Signifikan
ROA	$\hat{z} = -1,601 + 0,0212x_2$	Tidak
ROE	$\hat{z} = -1,1936 - 0,0119x_3$	Signifikan
NIM	$\hat{z} = 96,86 - 28,61x_4$	Tidak
BOPO	$\hat{z} = -4,5012 + 0,0169x_5$	Tidak
Aktiva Produktif Bermasalah	$\hat{z} = -1,3965 + 0,0062x_6$	Tidak
NPL	$\hat{z} = -1,4529 + 0,0082x_7$	Tidak
PPAP Terhadap Aktiva Produktif	$\hat{z} = -1,1210 - 0,0604x_8$	Tidak
Pemenuhan PPAP	$\hat{z} = -0,4672 - 0,0039x_9$	Tidak
CAR	$\hat{z} = -1,2091 - 0,0035x_{10}$	Tidak
ATTM	$\hat{z} = -1,3823 + 0,0005x_{11}$	Tidak
Inflasi	$\hat{z} = -26,924 + 1,502M_1$	Tidak
Pertumbuhan Ekonomi	$\hat{z} = -154,07 + 26,81M_2$	Tidak

Uji signifikansi parameter yang dilakukan pada model menghasilkan kesimpulan bahwa terdapat dia variabel yang berpengaruh signifikan terhadap kondisi *financial distress* bank umum di Indonesia. Variabel yang berpengaruh secara signifikan adalah LDR dan ROE. Model-model tersebut kemudian digunakan untuk mengkalsifikasikan bank pada data *training* dan data *testing*. Tabel 4.44 menunjukkan nilai ketepatan klasifikasi dari metode GEVR untuk masing-masing variabel pada skema *window size* 3.

Tabel 4.44 Ketepatan Klasifikasi GEVR Univariat Pada *Size 3*

	<i>Training</i>		<i>Testing</i>	
	Akurasi	AUC	Akurasi	AUC
LDR	0,9864	0,5000	0,9733	0,5000
ROA	0,9864	0,5000	0,9733	0,5000
ROE	0,9864	0,7466	0,9733	0,7432
NIM	0,0204	0,5034	0,9733	0,5000
BOPO	0,9932	0,7500	0,9733	0,7432
Aktiva Produktif Bermasalah	0,9864	0,5000	0,9733	0,5000
NPL	0,9864	0,5000	0,9733	0,5000
PPAP Terhadap Aktiva Produktif	0,9864	0,5000	0,9733	0,5000
Pemenuhan PPAP	0,9864	0,5000	0,9733	0,5000
CAR	0,9864	0,5000	0,9733	0,5000
ATTM	0,9864	0,5000	0,9733	0,5000
Inflasi	0,9864	0,5000	0,9733	0,5000
Pertumbuhan Ekonomi	0,9864	0,5000	0,9733	0,5000

Sejalan dengan *window size* lainnya, nilai AUC yang dihasilkan hanya berkisar pada nilai 50% hingga 75%. Artinya, klasifikasi yang dihasilkan oleh metode GEVR secara univariat cenderung menghasilkan nilai AUC sebesar 50% hingga 75%. Kesalahan klasifikasi pada metode GEVR yang dilakukan secara univariat adalah bank dengan kondisi *financial distress* gagal diklasifikasikan sebagai bank dengan *financial distress*.

c. **Pemodelan *Financial Distress* dengan GEVR dengan *Stepwise***

Hasil pemodelan *financial distress* bank umum dengan metode GEVR secara serentak menghasilkan variabel yang signifikan dengan jumlah yang sedikit, namun dapat menghasilkan akurasi prediksi yang tinggi. Evaluasi terhadap hasil tersebut dilakukan dengan memodelkan variabel-variabel

yang terpilih dengan prosedur *stepwise*. Variabel yang terpilih tercantum pada Tabel 4.45.

Tabel 4.45 Variabel Terpilih Pada GEVR

<i>Size</i>	Variabel	<i>Step</i>
0	NIM	13
1	ROE	10
	NPL	
	CAR	
	Pertumbuhan Ekonomi	
2	NIM BOPO	12
3	ROE	9
	BOPO	
	NPL	
	PPAP Terhadap Aktiva Produktif Inflasi	

Variabel yang telah terpilih melalui prosedur *stepwise* kemudian dimodelkan kembali. Model baru yang terbentuk kemudian digunakan untuk membuat klasifikasi baru terhadap bank dalam data *training* dan data *testing*. Model yang terbentuk dari variabel-variabel terpilih pada Tabel 4.45 dirangkum pada Tabel 4.46.

Tabel 4.46 Model Prediksi *Financial Distress* dengan GEVR Menggunakan *Stepwise*

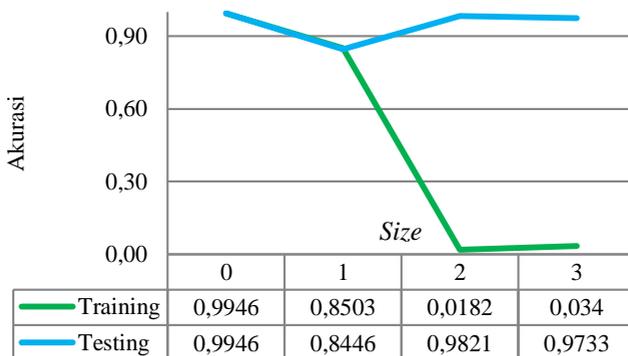
<i>Size</i>	Model
0	$\hat{z} = -0,5543 - 0,1501x_4$
1	$\hat{z} = -0,0107 + 0,0629x_3 + 0,3039x_7 + 0,0234x_7 + 0,1594M_2$
2	$\hat{z} = 2899,49 - 573,944x_4 - 7,4645x_5$
3	$\hat{z} = -2219 + 6,655x_3 + 1,129x_5 + 4,205x_7 - 178,9x_8 + 2,633M_1$

Klasifikasi kemudian dilakukan dengan model baru yang terbentuk. Dengan model tersebut, dihitung peluang suatu bank masuk dalam klasifikasi bank sehat atau bank dengan *financial distress*. Ketepatan klasifikasi yang dihasilkan dari model pada Tabel 4.46 berada pada Tabel 4.47.

Tabel 4.47 Ketepatan Klasifikasi GEVR dengan *Stepwise*

Size	Training		Testing	
	Akurasi	AUC	Akurasi	AUC
0	0,9946	0,7486	0,9946	0,7500
1	0,8503	0,4281	0,8446	0,4281
2	0,0182	0,5046	0,9821	0,5000
3	0,0340	0,5103	0,9733	0,5000

Nilai akurasi yang dihasilkan pada skema *window size* 0 dan 1 baik untuk data *training* maupun data *testing* bernilai lebih dari 90%. Namun pada skema *window size* 2 dan 3, nilai akurasi untuk data *training* menurun hingga 1,82% dan 3,4% saja. Kesalahan klasifikasi yang terjadi adalah banyaknya bank sehat yang diklasifikasikan sebagai bank dengan kondisi *financial distress*. Nilai-nilai akurasi dari data *training* dan *testing* digambarkan pada Gambar 4.37.

**Gambar 4.37** Nilai Akurasi Metode GEVR dengan *Stepwise*

Perbedaan nilai akurasi yang signifikan terlihat pada skema *window size* 2 dan 3, dimana nilai akurasi data *training* sangat kecil namun nilai akurasi data *testing* sangat besar. Kesalahan klasifikasi yang terjadi pada metode ini cukup berbeda dengan metode lainnya. Pada GEVR dengan *stepwise* bank sehat banyak diklasifikasikan sebagai bank dengan *financial distress*.

4.7 Perbandingan Kebaikan Model

Klasifikasi bank telah dilakukan dengan empat metode yaitu analisis diskriminan linier, analisis diskriminan kernel, regresi logistik biner, serta GEVR. Keempat metode tersebut menghasilkan ketepatan klasifikasi yang beragam. Klasifikasi terbaik dapat ditentukan dari tingginya nilai AUC yang dihasilkan baik pada data *training* maupun pada data *testing*. Terdapat tiga cara untuk memodelkan kondisi bank yaitu secara serentak, secara univariat, serta dengan menggunakan seleksi *stepwise*.

a. Perbandingan Kebaikan Model

Pemodelan pertama dilakukan secara serentak, yaitu dengan mengikutsertakan seluruh variabel kedalam model. Tabel 4.48 menunjukkan nilai ketepatan klasifikasi dari data *training* keempat metode untuk seluruh *window size* dengan melibatkan seluruh variabel prediktor.

Tabel 4.48 Perbandingan AUC Data *Training*

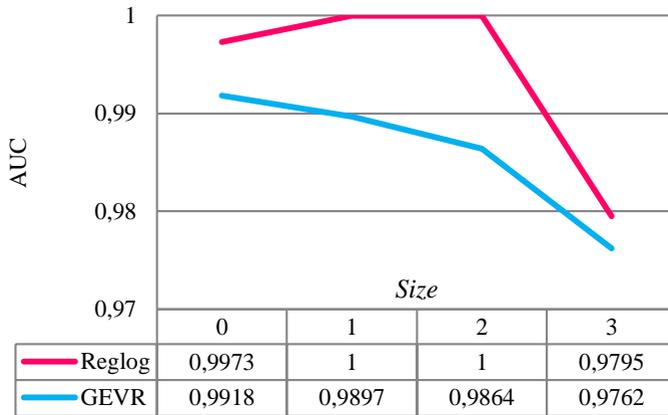
Size	Analisis Diskriminan Linier	Analisis Diskriminan Kernel	Regresi Logistik Biner	GEVR
	AUC	AUC	AUC	AUC
0	0,7500	0,7500	1	1
1	0,7483	0,7500	1	1
2	0,7477	0,7500	1	1
3	0,7500	0,7500	1	1

Perbedaan nilai AUC yang signifikan terlihat antara metode analisis diskriminan dengan metode regresi pada data *training*. Tabel 4.49 menunjukkan perbedaan nilai AUC untuk seluruh metode pada seluruh *window size*.

Tabel 4.49 Perbandingan AUC Data *Testing*

<i>Size</i>	Analisis Diskriminan Linier	Analisis Diskriminan Kernel	Regresi Logistik Biner	GEVR
	AUC	AUC	AUC	AUC
0	0,7473	0,7500	0,9973	0,9918
1	0,7432	0,7500	1	0,9897
2	0,7500	0,7500	1	0,9864
3	0,7432	0,7500	0,9795	0,9762

Nilai AUC dari data *testing* menunjukkan pola yang serupa dengan data *training*. Metode analisis diskriminan menghasilkan nilai yang lebih kecil dari metode regresi baik pada data *training* maupun pada data *testing*. Klasifikasi yang dihasilkan metode analisis diskriminan linier dan analisis diskriminan kernel hanya masuk dalam kategori *fair classification*. AUC dari metode lainnya yaitu regresi logistik biner dan GEVR menunjukkan bahwa kedua metode telah menghasilkan klasifikasi yang sangat baik atau dapat dikategorikan dalam *excellent classification*. Perbedaan nilai AUC data *testing* untuk metode regresi logistik biner dan GEVR dapat terlihat pada Gambar 4.38



Gambar 4.38 Perbandingan AUC Data *Testing* Regresi Logistik dan GEVR

Gambar 4.38 menunjukkan bahwa AUC dari metode regresi logistik biner lebih baik dari metode GEVR. Namun, model yang dihasilkan metode regresi logistik biner tidak memiliki variabel yang secara signifikan berpengaruh pada prediksi kondisi bank, sedangkan model GEVR memiliki variabel yang signifikan pada *window size* 1 dan 3. Ringkasan dari jumlah variabel yang signifikan pada masing-masing metode adalah sebagai berikut:

Tabel 4.50 Perbandingan Jumlah Variabel Signifikan Secara Serentak

Size	Analisis Diskriminan	Analisis Diskriminan Kernel	Regresi Logistik	GEVR
0	13	11	Tidak Ada	Tidak Ada
1	13	4	Tidak Ada	2
2	13	2	Tidak Ada	Tidak Ada
3	13	8	Tidak Ada	1

Tabel 4.50 menunjukkan bahwa untuk seluruh *window size* pada metode regresi logistik biner, tidak terdapat variabel yang signifikan. Besarnya nilai AUC yang dihasilkan metode regresi logistik disebabkan adanya *muktikolinieritas* dimana terdapat hubungan yang tinggi antar variabel prediktor. Hal ini diperjelas dengan beberapa variabel yang menunjukkan

pengaruh yang signifikan apabila dilakukan pemodelan secara univariat maupun dengan metode *stepwise*.

Oleh sebab itu, metode GEVR dianggap lebih baik. Hal ini disebabkan metode GEVR memiliki variabel prediktor yang secara signifikan berpengaruh terhadap kondisi *financial distress* bank dan menghasilkan nilai AUC yang tidak jauh berbeda dari regresi logistik.

b. Perbandingan Kebaikan Model Secara Univariat

Indikasi *multikolinieritas* pada data diatasi dengan memodelkan variabel secara univariat. Model univariat mampu memberikan informasi terkait variabel-variabel yang berpengaruh signifikan pada kondisi *financial distress* pada bank umum di Indonesia. Tabel 4.51 menunjukkan perbandingan jumlah variabel yang signifikan pada masing-masing *size*.

Tabel 4.51 Perbandingan Jumlah Variabel Signifikan Secara Univariat

<i>Size</i>	Analisis Diskriminan	Regresi Logistik	GEVR
0	13	8	4
1	13	4	3
2	13	2	4
3	13	2	2

Metode klasifikasi analisis diskriminan mampu menghasilkan variabel yang berpengaruh signifikan lebih banyak dari metode regresi logistik biner maupun GEVR. Namun, pada penelitian ini, terdapat asumsi yang dilanggar pada metode analisis diskriminan linier yaitu asumsi distribusi normal multivariat. Metode lainnya yang telah memenuhi asumsi adalah regresi logistik dan GEVR. Jika dilakukan perbandingan, metode regresi logistik biner mampu menghasilkan variabel yang signifikan lebih banyak dari metode GEVR untuk setiap skema *window size*. Selain itu, nilai AUC juga dapat digunakan untuk menentukan metode terbaik. Tabel 4.52 menunjukkan nilai AUC data *training*.

Tabel 4.52 Perbandingan AUC Data *Training* Model Univariat Pada *Size* 0

Variabel	Analisis Diskriminan Linier	Regresi Logistik Biner	GEVR
	AUC	AUC	AUC
LDR	0,5000	0,5000	0,5000
ROA	0,7486	0,4954	0,4986
ROE	0,7500	0,7431	0,7486
NIM	0,7486	0,5000	0,7486
BOPO	0,7500	0,7454	0,7486
Aktiva Produktif Bermasalah	0,7459	0,4977	0,4986
NPL	0,7418	0,4954	0,4986
PPAP Terhadap Aktiva Produktif	0,7459	0,5000	0,4973
Pemenuhan PPAP	0,5000	0,5000	0,5000
CAR	0,5000	0,5000	0,4986
ATTM	0,5000	0,4977	0,5000
Inflasi	0,5000	0,5000	0,5000
Pertumbuhan Ekonomi	0,5000	0,5000	0,5000

Tidak terdapat perbedaan signifikan antara nilai AUC dari data *training* yang dihasilkan oleh metode analisis diskriminan, regresi logistik, maupun GEVR. Nilai AUC yang dihasilkan berkisar antara nilai 50%-75%. Tabel 4.53 merupakan nilai AUC dari data *testing* pada skema *window size* 0.

Tabel 4.53 Perbandingan AUC Data *Testing* Model Univariat Pada *Size* 0

Variabel	Analisis Diskriminan Linier	Regresi Logistik Biner	GEVR
	AUC	AUC	AUC
LDR	0,5000	0,5000	0,5000
ROA	0,7473	0,5000	0,4973
ROE	0,7500	0,7500	0,7500
NIM	0,7500	0,5000	0,7500
BOPO	0,7473	0,7500	0,7473
Aktiva Produktif Bermasalah	0,7500	0,5000	0,5000
NPL	0,7473	0,5000	0,5000
PPAP Terhadap Aktiva Produktif	0,7500	0,5000	0,5000
Pemenuhan PPAP	0,5000	0,5000	0,5000
CAR	0,5000	0,5000	0,4973
ATTM	0,5000	0,4955	0,5000
Inflasi	0,5000	0,5000	0,5000
Pertumbuhan Ekonomi	0,5000	0,5000	0,5000

Nilai AUC yang dihasilkan data *testing* juga tidak memiliki perbedaan yang signifikan untuk metode yang berbeda. Nilai AUC dari data *training* dan data *testing* juga tidak memiliki perbedaan yang signifikan pada skema *window size* 0. Tabel 4.54 merupakan nilai AUC dari data *training* pada model univariat pada skema *window size* 1.

Tabel 4.54 Perbandingan AUC Data *Training* Model Univariat Pada *Size* 1

Variabel	Analisis Diskriminan Linier	Regresi Logistik Biner	GEVR
	AUC	AUC	AUC
LDR	0,5000	0,5000	0,5000
ROA	0,4966	0,5000	0,4966
ROE	0,7449	0,7500	0,7500
NIM	0,7500	0,7500	0,7500
BOPO	0,7466	0,7500	0,7500
Aktiva Produktif Bermasalah	0,4966	0,5000	0,4983
NPL	0,7466	0,5000	0,4983
PPAP Terhadap Aktiva Produktif	0,5000	0,5000	0,5000
Pemenuhan PPAP	0,5000	0,5000	0,5000
CAR	0,5000	0,5000	0,5000
ATTM	0,5000	0,5000	0,5000
Inflasi	0,5000	0,5000	0,5000
Pertumbuhan Ekonomi	0,5000	0,5000	0,5000

Hasil dari AUC data *training* pada skema *window size* 1 hampir menyerupai nilai AUC pada skema *window size* 0. Tidak terdapat perbedaan signifikan antara nilai AUC dari data *training* yang dihasilkan oleh metode analisis diskriminan, regresi logistik, maupun GEVR. Nilai AUC yang dihasilkan berkisar antara nilai 50%-75%. Tabel 4.55 merupakan nilai AUC dari data *testing* pada skema *window size* 1.

Tabel 4.55 Perbandingan AUC Data *Testing* Model Univariat Pada *Size 1*

Variabel	Analisis Diskriminan Linier	Regresi Logistik Biner	GEVR
	AUC	AUC	AUC
LDR	0,5000	0,5000	0,5000
ROA	0,5000	0,5000	0,5000
ROE	0,7432	0,7500	0,7500
NIM	0,7500	0,7500	0,7500
BOPO	0,7466	0,7500	0,7500
Aktiva Produktif Bermasalah	0,4955	0,5000	0,4966
NPL	0,7466	0,5000	0,5000
PPAP Terhadap Aktiva Produktif	0,5000	0,5000	0,5000
Pemenuhan PPAP	0,5000	0,5000	0,5000
CAR	0,5000	0,5000	0,5000
ATTM	0,4966	0,5000	0,4966
Inflasi	0,5000	0,5000	0,5000
Pertumbuhan Ekonomi	0,5000	0,5000	0,5000

Hasil yang serupa juga didapatkan untuk nilai AUC data *testing* pada model univariat dengan skema *window size 1*. Selanjutnya dilakukan hal yang sama pada skema *window size 2*. Tabel 4.56 merupakan tabel perbandingan AUC data *training* pada skema *window size 2*.

Tabel 4.56 Perbandingan AUC Data *Training* Model Univariat Pada *Size 2*

Variabel	Analisis Diskriminan Linier	Regresi Logistik Biner	GEVR
	AUC	AUC	AUC
LDR	0,5000	0,5000	0,5000
ROA	0,4954	0,5000	0,5000
ROE	0,7431	0,5000	0,5000
NIM	0,5000	0,7500	0,7500
BOPO	0,7454	0,5000	0,4977
Aktiva Produktif Bermasalah	0,4977	0,5000	0,4977
NPL	0,4954	0,5000	0,5000
PPAP Terhadap Aktiva Produktif	0,5000	0,5000	0,4954
Pemenuhan PPAP	0,5000	0,5000	0,5000
CAR	0,5000	0,5000	0,5000
ATTM	0,4977	0,5000	0,5000
Inflasi	0,5000	0,5000	0,5000
Pertumbuhan Ekonomi	0,5000	0,5000	0,5000

Hasil yang serupa didapatkan skema *window size 2*. Tidak terdapat perbedaan signifikan antara nilai AUC dari data *training* yang dihasilkan oleh metode analisis diskriminan, regresi logistik, maupun GEVR. Nilai AUC yang dihasilkan berkisar antara nilai 50%-75%. Tabel 4.57 merupakan nilai AUC dari data *testing* pada skema *window size 2*.

Tabel 4.57 Perbandingan AUC Data *Testing* Model Univariat Pada *Size 2*

Variabel	Analisis Diskriminan Linier	Regresi Logistik Biner	GEVR
	AUC	AUC	AUC
LDR	0,5000	0,5000	0,5000
ROA	0,5000	0,5000	0,5000
ROE	0,7500	0,5000	0,4955
NIM	0,5000	0,7500	0,7500
BOPO	0,7500	0,5000	0,5000
Aktiva Produktif Bermasalah	0,5000	0,5000	0,5000
NPL	0,5000	0,5000	0,5000
PPAP Terhadap Aktiva Produktif	0,5000	0,5000	0,5000
Pemenuhan PPAP	0,5000	0,5000	0,5000
CAR	0,5000	0,5000	0,5000
ATTM	0,4955	0,5000	0,5000
Inflasi	0,5000	0,5000	0,5000
Pertumbuhan Ekonomi	0,5000	0,5000	0,5000

Hasil yang serupa juga didapatkan untuk nilai AUC data *testing* pada model univariat dengan skema *window size 2*. Tabel 4.58 merupakan tabel perbandingan AUC data *training* pada skema *window size 3*.

Tabel 4.58 Perbandingan AUC Data *Training* Model Univariat Pada *Size* 3

Variabel	Analisis Diskriminan Linier	Regresi Logistik Biner	GEVR
	AUC	AUC	AUC
LDR	0,5000	0,5000	0,5000
ROA	0,7500	0,7500	0,5000
ROE	0,7466	0,7500	0,7466
NIM	0,5000	1	0,5034
BOPO	0,7500	0,7500	0,7500
Aktiva Produktif Bermasalah	0,5000	0,5000	0,5000
NPL	0,4966	0,5000	0,5000
PPAP Terhadap Aktiva Produktif	0,5000	0,5000	0,5000
Pemenuhan PPAP	0,5000	0,5000	0,5000
CAR	0,5000	0,5000	0,5000
ATTM	0,5000	0,5000	0,5000
Inflasi	0,5000	0,5000	0,5000
Pertumbuhan Ekonomi	0,5000	0,5000	0,5000

Hasil yang serupa didapatkan skema *window size* 3. Tidak terdapat perbedaan signifikan antara nilai AUC dari data *training* yang dihasilkan oleh metode analisis diskriminan, regresi logistik, maupun GEVR. Namun pada variabel NIM mampu menghasilkan nilai AUC sebesar 1, namun jika dilihat kembali, variabel NIM bukan merupakan variabel yang berpengaruh signifikan terhadap kondisi *financial distress* bank umum di Indonesia. Tabel 4.59 merupakan nilai AUC dari data *testing* pada skema *window size* 3.

Tabel 4.59 Perbandingan AUC Data *Testing* Model Univariat Pada *Size* 3

Variabel	Analisis Diskriminan Linier	Regresi Logistik Biner	GEVR
	AUC	AUC	AUC
LDR	0,5000	0,5000	0,5000
ROA	0,7432	0,7432	0,5000
ROE	0,7432	0,7432	0,7432
NIM	0,5000	0,9932	0,5000
BOPO	0,7432	0,7432	0,7432
Aktiva Produktif Bermasalah	0,5000	0,5000	0,5000
NPL	0,5000	0,5000	0,5000
PPAP Terhadap Aktiva Produktif	0,5000	0,5000	0,5000
Pemenuhan PPAP	0,5000	0,5000	0,5000
CAR	0,5000	0,5000	0,5000
ATTM	0,5000	0,5000	0,5000
Inflasi	0,5000	0,5000	0,5000
Pertumbuhan Ekonomi	0,5000	0,5000	0,5000

Nilai AUC yang dihasilkan berkisar antara nilai 50%-75%. Namun terdapat satu nilai AUC yang bernilai 99% yaitu pada metode regresi logistik variabel NIM. Walaupun menghasilkan nilai AUC yang tinggi, tetapi NIM bukan merupakan variabel yang berpengaruh signifikan pada kondisi bank.

Secara univariat, metode regresi logistik terlihat lebih baik untuk kasus prediksi *financial distress* bank umum. Hal ini dikarenakan jumlah variabel yang berpengaruh signifikan pada metode regresi logistik lebih banyak dari yang lainnya.

Nilai AUC antara ketiga metode juga tidak memiliki perbedaan yang signifikan.

c. Perbandingan Keباikan Model dengan *Stepwise*

Metode lain yang dapat digunakan selain dengan memodelkan variabel secara univariat adalah dengan melakukan seleksi variabel. Salah satu cara melakukan seleksi variabel adalah dengan menggunakan metode *stepwise*. Variabel yang berpengaruh signifikan pada masing-masing metode tercantum pada Tabel 4.60

Tabel 4.60 Perbandingan Jumlah Variabel Signifikan dengan *Stepwise*

<i>Size</i>	Analisis Diskriminan	Analisis Diskriminan Kernel	Regresi Logistik	GEVR
0	4	3	2	1
1	3	3	3	4
2	3	Tidak Ada	3	2
3	1	2	4	5

Metode GEVR mampu menghasilkan jumlah tertinggi untuk variabel yang signifikan pada *size* 1 dan *size* 3. Hal ini menunjukkan bahwa dengan *stepwise* metode GEVR mampu menghasilkan variabel yang signifikan lebih banyak dari ketiga metode lainnya. Kesimpulan mengenai metode terbaik juga dilihat dari ketepatan klasifikasi yang dihasilkan. Tabel 4.61 merupakan nilai AUC untuk data *training*.

Tabel 4.61 Perbandingan AUC Data *Training* dengan *Stepwise*

<i>Size</i>	Analisis Diskriminan Linier	Analisis Diskriminan Kernel	Regresi Logistik Biner	GEVR
	AUC	AUC	AUC	AUC
0	0,7500	1	1	0,7486
1	0,7483	0,7500	1	0,4281
2	0,7454	0,7500	1	0,5046
3	0,7500	0,7500	1	0,5103

Nilai AUC Data *training* tertinggi dihasilkan oleh metode regresi logistik dengan nilai AUC sebesar 100% untuk setiap skema *window size*. Metode lainnya hanya menghasilkan AUC sebesar 75% bahkan metode GEVR hanya mampu menghasilkan AUC sebesar 50%. Tabel 4.62 merupakan nilai AUC untuk data *testing*

Tabel 4.62 Perbandingan AUC Data *Testing* dengan *Stepwise*

<i>Size</i>	Analisis Diskriminan Linier	Analisis Diskriminan Kernel	Regresi Logistik Biner	GEVR
	AUC	AUC	AUC	AUC
0	0,7473	1	0,9973	0,7486
1	0,7432	0,7500	0,9865	0,4281
2	0,7500	0,7500	1	0,5000
3	0,7432	0,7432	0,9600	0,5000

Hal serupa juga ditunjukkan pada hasil nilai AUC data *testing*. Nilai UAC metode regresi logistik jauh lebih tinggi dari metode lainnya. Pada kasus kondisi *financial distress* bank umum di Indonesia dengan menggunakan *stepwise*, metode regresi logistik menghasilkan ketepatan klasifikasi yang lebih baik.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis yang telah dilakukan, didapatkan kesimpulan sebagai berikut:

1. Beberapa rasio keuangan dari Bank Century dan Bank IFI menggambarkan bahwa Bank Century dan Bank IFI mengalami *financial distress*. Hal ini digambarkan oleh perbedaan signifikan yang ditunjukkan rasio keuangan Bank Century dan Bank IFI dengan rata-rata bank sehat lainnya. Bank IFI terlihat mengalami penurunan kondisi secara perlahan, namun Bank Century terlihat mengalami penurunan kondisi keuangan secara signifikan pada tahun 2008. Variabel kondisi makroekonomi seperti inflasi dan pertumbuhan ekonomi Indonesia juga menunjukkan bahwa secara keseluruhan, kondisi perekonomian Indonesia memburuk pada tahun 2008. Hal ini ditunjukkan dengan naiknya inflasi dan turunnya pertumbuhan ekonomi Indonesia pada tahun 2008.
2. Hasil uji signifikansi parameter untuk model serentak memberikan hasil bahwa regresi logistik tidak menghasilkan variabel yang signifikan didalam modelnya, sedangkan metode GEVR pada *size* 1 menghasilkan dua variabel yang signifikan yaitu aktiva produktif bermasalah dan pertumbuhan ekonomi dan pada *size* 3 yaitu BOPO. Secara univariat terdapat variabel yang signifikan untuk setiap metode pada masing-masing skema *window size*. Hal serupa juga terjadi apabila klasifikasi melibatkan proses *stepwise*. Model mampu menghasilkan variabel yang signifikan pada masing-masing metode dan skema *window size*. Kesalahan klasifikasi yang umum terjadi pada metode analisis diskriminan adalah bank dengan kondisi *financial distress* diklasifikasikan sebagai bank sehat. Hal tersebut juga terjadi apabila model dibuat secara univariat.

Sedangkan untuk metode GEVR dan Regresi logistik secara serentak, kesalahan klasifikasi yang terjadi adalah sebaliknya.

3. Pemodelan dilakukan dengan empat metode yaitu analisis diskriminan linier, analisis diskriminan kernel, regresi logistik biner, dan GEVR. Metode regresi logistik merupakan model terbaik pada kasus prediksi *financial distress* bank umum di Indonesia jika dilakukan secara univariat atau dengan menggunakan *stepwise*. Namun, metode GEVR lebih baik dari regresi logistik untuk memodelkan seluruh data rasio, inflasi, dan pertumbuhan ekonomi secara serentak. Hal ini merupakan kelebihan dari metode GEVR, dimana metode ini mampu menghasilkan variabel yang signifikan ketika metode lain seperti regresi logistik tidak mampu menghasilkan variabel yang signifikan.

5.2 Saran

Berdasarkan kesimpulan yang telah didapatkan, saran yang dapat diberikan adalah sebagai berikut:

1. Metode GEVR memerlukan nilai parameter τ yang dapat menghasilkan model terbaik, untuk penelitian selanjutnya, disarankan untuk mencobakan lebih banyak nilai τ agar model dapat menghasilkan klasifikasi yang lebih baik.
2. Penelitian ini menghasilkan model dengan parameter yang tidak signifikan. Hal ini diduga karena terdapat variabel yang memiliki hubungan yang tinggi satu sama lain. Penelitian selanjutnya disarankan untuk mengatasi hal ini dengan metode *feature extraction* agar dapat melibatkan seluruh variabel pada penelitian.

DAFTAR PUSTAKA

- Agresti, A. (2002). *Categorical Data Analysis Second Edition*. New Jersey: John Wiley & Sons, Inc.
- Al-Shaeya, Q. K., El-Rafae, G. A., & El-Itter, S. F. (2010). Neural Networks in Bank Insolvency Prediction. *International Journal of Computer Science and Network Security*, 10, 240-245.
- Altman, E. I. (1968). Financial Ratios, Discriminant Analysis and Prediction of Corporate Bankruptcy. *The Journal of Finance*, 23, 589-609.
- Bank Indonesia (BI). (2001). *Surat Edaran Bank Indonesia Nomor 3/30/DPNP*. Jakarta: Bank Indonesia.
- Bank Indonesia (BI). (2008). *Laporan Perekonomian Indonesia Tahun 2008*. Jakarta: Bank Indonesia.
- Calabrese, R., & Guidici, P. (2015). Estimating Bank Default with Generalised Extreme Value Regression Models. *Journal of The Operational Research Society*, 66, 1783-1792.
- Calabrese, R., & Osmetti, S. A. (2013). Modelling Small and Medium Enterprise Loan Defaults as Rare Events: The Generalized Extreme Value Regression Model. *Journal of Applied Statistics*, 40, 1172-1188.
- Dharmawan, K. (2012). Estimasi Nilai VaR Dinamis Indeks Saham Menggunakan Peak-Over Treshold dan Block Maxima. *Jurnal Matematika*, 2, 1-12.
- Fahmi, I. (2016). *Pengantar Manajemen Keuangan*. Bandung: Alfabeta.
- Fallo, J. O., Setiawan, A., & Susanto, B. (2013). Uji Normalitas Berdasarkan Metode Anderson-Darling, Creamer-Von Mises dan Liliefors Menggunakan Metode Bootstrap. *Seminar Nasional Matematika dan Pendidikan Matematika*, (pp. 152-153). Yogyakarta.

- Gilli, M., & Kellezi, E. (2006). An Application of Extreme Value Theory for Measuring Financial Risk. *Computational Economic*, 27, 207-228.
- Gutmann, I., Wilks, S. S., & Hunter, J. S. (1982). *Introductory Engineering Statistics Third Edition*. New York: John Wiley & Sons.
- Han, J., Kamber, M., & Pei, J. (2011). *Data Mining: Concept and Techniques Third Edition*. New York: Elsevier.
- Hardle, K. W., & Prastyo, D. D. (2014). Embedded Predictor Selection Default Risk Calculation: A Southeast Asian Industry Study. In *Handbook of Asian Finance: Financial Market and Sovereign Wealth Fund* (pp. 131-148). San Diego: Academic Press.
- Hardle, W. K., Prastyo, D. D., & Hafner, C. M. (2014). Support Vector Machines with Evolutionary Model Selection for Default Prediction. In J. Racine, L. Su, & A. Ullah (Eds.), *The Oxford Handbook of Applied Nonparametric and Semiparametric Econometrics and Statistics* (pp. 346-373). New York: Oxford University Press.
- Johnson, R. A., & Wichern, D. W. (2007). *Applied Multivariate Statistical Analysis Sixth Edition*. New Jersey: Pearson Prentice Hall.
- Klinkenberg, R. (2013). *Using Labeled and Unlabeled Data to Learn Drifting Concept*. Dortmund: University of Dortmund.
- Kowarik, A., & Templ, M. (2016). Imputation with the R Package VIM. *Journal of Statistical Software*, 74(7), 1-16.
- Lembaga Penjamin Simpanan (LPS). (2004). *Undang-Undang Republik Indonesia Nomor 24 Tahun 2004 tentang Lembaga Penjamin Simpanan*. Jakarta.

- Mika, S., Ratsch, G., Jason, W., Scholkopf, B., & Muller, K. R. (1999). *Fisher Discriminant Analysis with Kernel*. Egham: University of London.
- Mulyaningrum, P. (2008). *Pengaruh Rasio Keuangan Terhadap Kebangkrutan Bank di Indonesia*. Thesis. Semarang: Universitas Diponegoro.
- Nastiti, W. K. (2016). *Estimasi Risiko Investasi Saham Perusahaan Sektor Telekomunikasi di Bursa Efek Indonesia (BEI) Menggunakan Metode Conditional Value at Risk (VaR) dengan Pendekatan ARMA-GARCH dan Extreme Value Theory (EVT)*. Tugas Akhir. Surabaya: ITS.
- Otoritas Jasa Keuangan (OJK). (2017). *Salinan Peraturan Otoritas Jasa Keuangan Nomor 15/POJK.03/2017 Tentang Penetapan Status dan Tindak Lanjut Pengawasan Bank Umum*. Jakarta: Otoritas Jasa Keuangan.
- Rahmaniah, M., & Wibowo, H. (2015). Analisis Potensi Terjadinya Financial Distress pada Bank Umum Syariah di Indonesia. *Jurnal Ekonomi dan Perbankan Syariah*, 3, 1-20.
- Rencher, A. C. (2002). *Methods of Multivariate Analysis* (2 ed.). Canada: John Wiley & Sons, Inc.
- Saputri, P. D. (2017). *Aplikasi Model Hybrid Quantile Regression Neural Network pada Pecahan Inflow dan Outflow Uang Kartal di Indonesia*. Tugas Akhir. Surabaya: ITS.
- Sentosa, P. B., & Hamdani, M. (2007). *Statistika Deskriptif dalam Bidang Ekonomi dan Niaga*. Jakarta: Erlangga.
- Sudarsono, H. (2009). Dampak Krisis Keuangan Global Terhadap Perbankan di Indonesia: Perbandingan antara Bank Konvensional dan Bank Syariah. *La_Riba Jurnal Ekonomi Islam*, 3, 12-23.

- Sukirno, S. (2013). *Makroekonomi Teori Pengantar*. Jakarta: PT Rajagrafindo Persada.
- Unit Khusus Museum Bank Indonesia. (n.d.). *Unit Khusus Museum Bank Indonesia: Sejarah Bank Indonesia*. Diakses pada September 16, 2017, dari Bank Indonesia: <http://www.bi.go.id>
- Walpole, R. E., Myers, R. H., Myers, S. L., & Ye, K. (2007). *Probability & Statistics for Engineers & Scientist*. New Jersey: Pearson Prentice Hall.
- Wang, X., & Dey, D. K. (2010). Generalized Extreme Value Regression for Binary Response Data: An Application to B2B Electronic Payments System Adoption. *The Annals of Applied Statistics*, 4, 2000-2023.
- Weiss, N. A. (2008). *Introductory Statistics Eighth Edition*. Boston: Pearson Education, Inc.
- Witten, I. H., Fraink, E., & Hall, M. A. (2011). *Data Mining Practical Machine Learning Tools and Technique Third Edition*. New York: Elsevier.
- Wulandari, F. D. (2016). *Prediksi Finansial Distress Perusahaan Go-Public Sektor Jasa Non-Finance Menggunakan Analisis Diskriminan, Regresi Logistik Biner dan Radial Basic Function Network*. Tugas Akhir. Surabaya: ITS.
- Yuniarti, I. (2015). *Prediksi Finansial Distress Perusahaan Sektor Manufaktur dan Industri Penghasil Bahan Baku Utama yang Terdaftar di Bursa Efek Indonesia Menggunakan Analisis Diskriminan, Regresi Logistik Biner, dan Feedforward Neural Network*. Tugas Akhir. Surabaya: ITS.
- Zhang, G., Hu, M. Y., Patuwo, B. E., & Indro, D. C. (1997). Artificial Neural Networks in Bankruptcy Prediction: General Framework and Cross-Validation Analysis. *European Journal of Operational Research*, 16-32.

LAMPIRAN

Lampiran 1. Data Rasio Keuangan Bank dan Kondisi
Ekonomi Indonesia 2004-2008

Bank	Tahun	X1	X2	...	M2	Y
1	2004	2,92	26,44	...	5,1	0
	2005	3,35	46,97	...	5,7	0
	2006	5,12	87,02	...	5,5	0
	2007	5,81	72,9	...	6,3	0
	2008	6,16	73,52	...	6,1	0
2	2004	1,75	19,24	...	5,1	0
	2005	2,27	23,46	...	5,7	0
	2006	2,08	18,78	...	5,5	0
	2007	1,45	13,34	...	6,3	0
	2008	1,19	9,33	...	6,1	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮
109	2004	46,34	5,29	...	5,1	0
	2005	42,43	5,08	...	5,7	0
	2006	37,05	6,58	...	5,5	0
	2007	47,11	6,21	...	6,3	0
	2008	73,24	5,38	...	6,1	0
110	2004	94,43	8,08	...	5,1	0
	2005	76,21	7,43	...	5,7	0
	2006	52,44	6,22	...	5,5	0
	2007	40,69	5,98	...	6,3	0
	2008	49,99	6,44	...	6,1	0

Lampiran 2. Hasil *Box's M Test*

Box's M-test for Homogeneity of Covariance Matrices

data: data[, -14]

Chi-Sq (approx.) = -Inf, df = 91, p-value = 1

Lampiran 3. Hasil Uji Distribusi Normal Multivariat

Mardia's Multivariate Normality Test

data : data[, -14]

g1p : 1335.878

chi.skew : 122455.5

p.value.skew : 0

g2p : 1717.204

z.kurtosis : 903.8407

p.value.kurt : 0

chi.small.skew : 123219.2

p.value.small : 0

Result : Data are not multivariate normal.

Lampiran 4. Hasil Uji Beda Rata-Rata Antar Kelompok
Secara Serentak

Wilks' Lambda				
Test of Function(s)	Wilks' Lambda	Chi-square	df	Sig.
1	.514	360.303	13	.000

Lampiran 5. Hasil Uji Beda Rata-Rata Antar Kelompok
Secara Parsial

Descriptive Discriminant Analysis		

\$power	discriminant power	
\$values	table of eigenvalues	
\$discrivar	discriminant variables	
\$discor	correlations	
\$scores	discriminant scores	

\$power		
	cor_ratio	wilks_lamb
LDR		
	0.0000592343299	0.9999407656701
ROA		
	0.0488329490418	0.9511670509582
ROE		
	0.4381381909686	0.5618618090314
NIM		
	0.0263725108271	0.9736274891729
BOPO		
	0.0033853833051	0.9966146166949
AKTIVA.PRODUKTIF.BERMASALAH		
	0.1250977934584	0.8749022065416
NPL		
	0.0481624542910	0.9518375457090
PPAP.TERHADAP.AKTIVA.PRODUKTIF		
	0.0681652022954	0.9318347977046
PEMENUHAN.PPAP		
	0.0008154570005	0.9991845429995
CAR		
	0.0028126109087	0.9971873890913
ATTM		
	0.0000542838416	0.9999457161584

INFLASI

0.0004779703342 0.9995220296658

PERTUMBUHAN.EKONOMI

0.0025931617365 0.9974068382635

F_statistic

p_values

LDR

0.0324623356746 0.8570833042624

ROA

28.1343388082265 0.0000001644914

ROE

3287929370649 0.0000000000000 427.

NIM

14.8435989060871 0.0001306215112

BOPO

1.8614919148292 0.1730127337996

AKTIVA.PRODUKTIF.BERMASALAH

78.3557182764515 0.0000000000000

NPL

27.7284974420745 0.0000002008194

PPAP.TERHADAP.AKTIVA.PRODUKTIF

40.0870743933071 0.0000000005061

PEMENUHAN.PPAP

0.4472351372756 0.5039324844824

CAR

1.5456581128228 0.2143091960837

ATTM

0.0297491600788 0.8631242976986

INFLASI

0.2620529967078 0.6089194399550

PERTUMBUHAN.EKONOMI

1.4247472315840 0.2331400756209

\$values

	value	proportion	accumulated
DF1	0.938	100.000	100.000

\$discrivar

	DF1
constant	1.109e+00
LDR	-2.046e-04
ROA	3.245e-02
ROE	-2.749e-02
NIM	1.271e-02
BOPO	4.167e-05
AKTIVA.PRODUKTIF.BERMASALAH	-2.239e-03
NPL	9.058e-03
PPAP.TERHADAP.AKTIVA.PRODUKTIF	1.972e-02
PEMENUHAN.PPAP	3.352e-04
CAR	-4.561e-03
ATTM	-5.166e-03
INFLASI	1.027e-02
PERTUMBUHAN.EKONOMI	-6.993e-02

\$discor

	DF1
LDR	-0.01104
ROA	-0.31701
ROE	-0.94956
NIM	-0.23297
BOPO	0.08347
AKTIVA.PRODUKTIF.BERMASALAH	0.50739

```
$scores
      z1
1  0.04237
2 -0.39272
3 -1.59932
4 -1.22540
5 -1.18364
6  0.10318
...
```

Lampiran 6. Uji Signifikansi Parameter Analisis Diskriminan
Linier

Size = 0

	Df	Sum Sq	Mean Sq	F Value	Pr(>F)
LDR	1	0.1	0.1	1.51E+30	<2e-16
ROA	1	138.2	138.2	2.15E+33	<2e-16
ROE	1	655.2	655.2	1.02E+34	<2e-16
NIM	1	0.1	0.1	2.02E+30	<2e-16
BOPO	1	78.4	78.4	1.22E+33	<2e-16
Aktiva Produktif Bermasalah	1	0.1	0.1	2.20E+30	<2e-16
NPL	1	2.9	2.9	4.56E+31	<2e-16
PPAP Terhadap Aktiva Produktif	1	0.4	0.4	6.83E+30	<2e-16
Pemenuhan PPAP	1	0	0	1.17E+29	<2e-16
CAR	1	4.4	4.4	6.90E+31	<2e-16
ATTM	1	27.9	27.9	4.34E+32	<2e-16
Inflasi	1	3.6	3.6	5.60E+31	<2e-16
Pertumbuhan Ekonomi	1	2.2	2.2	3.35E+31	<2e-16

Size = 1

	Df	Sum Sq	Mean Sq	F Value	Pr(>F)
LDR	1	0.26	0.26	1.19E+30	<2e-16
ROA	1	13.45	13.45	6.21E+31	<2e-16
ROE	1	237.97	237.97	1.10E+33	<2e-16
NIM	1	7.05	7.05	3.25E+31	<2e-16
BOPO	1	59.81	59.81	2.76E+32	<2e-16
Aktiva					
Produktif	1	0.81	0.81	3.73E+30	<2e-16
Bermasalah					
NPL	1	18.35	18.35	8.48E+31	<2e-16
PPAP Terhadap					
Aktiva Produkif	1	15.82	15.82	7.30E+31	<2e-16
Pemenuhan					
PPAP	1	7.09	7.09	3.28E+31	<2e-16
CAR	1	3.63	3.63	1.68E+31	<2e-16
ATTM	1	12.85	12.85	5.94E+31	<2e-16
Inflasi	1	0.44	0.44	2.02E+30	<2e-16
Pertumbuhan					
Ekonomi	1	9.27	9.27	4.28E+31	<2e-16

Size = 2

	Df	Sum Sq	Mean Sq	F Value	Pr(>F)
LDR	1	0.48	0.48	1.74E+30	<2e-16
ROA	1	4.98	4.98	1.80E+31	<2e-16
ROE	1	156.32	156.32	5.66E+32	<2e-16
NIM	1	11.47	11.47	4.15E+31	<2e-16
BOPO	1	59.62	59.62	2.16E+32	<2e-16
Aktiva Produktif	1	0.01	0.01	4.50E+28	<2e-16
Bermasalah					
NPL	1	8.66	8.66	3.14E+31	<2e-16
PPAP Terhadap Aktiva Produkif	1	13.59	13.59	4.92E+31	<2e-16
Pemenuhan PPAP	1	2.18	2.18	7.88E+30	<2e-16
CAR	1	7.33	7.33	2.65E+31	<2e-16
ATTM	1	0.06	0.06	2.00E+29	<2e-16
Inflasi	1	2.18	2.18	7.89E+30	<2e-16
Pertumbuhan Ekonomi	1	4.53	4.53	1.64E+31	<2e-16

Size = 3

	Df	Sum Sq	Mean Sq	F Value	Pr(>F)
LDR	1	0.3	0.3	5.14E+30	<2e-16
ROA	1	279.15	279.15	4.86E+33	<2e-16
ROE	1	0.64	0.64	1.11E+31	<2e-16
NIM	1	0.82	0.82	1.43E+31	<2e-16
BOPO	1	2.06	2.06	3.59E+31	<2e-16
Aktiva Produktif Bermasalah	1	1.51	1.51	2.62E+31	<2e-16
NPL	1	0.41	0.41	7.17E+30	<2e-16
PPAP Terhadap Aktiva Produktif	1	1.01	1.01	1.75E+31	<2e-16
Pemenuhan PPAP	1	0.03	0.03	5.86E+29	<2e-16
CAR	1	0.93	0.93	1.61E+31	<2e-16
ATTM	1	4.47	4.47	7.77E+31	<2e-16
Inflasi	1	1.95	1.95	3.39E+31	<2e-16

Lampiran 7. *Confussion Matrix* Klasifikasi dengan Metode Analisis Diskriminan Linier Secara Serentak

Size = 0

Data Training

<i>Predicted</i>	<i>Actual</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	365
<i>Total</i>	2	365

Data Testing

<i>Predicted</i>	<i>Actual</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	182
<i>Total</i>	2	183

Size = 1

Data Training

<i>Predicted</i>	<i>Actual</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	291
<i>Total</i>	2	292

Data Testing

<i>Predicted</i>	<i>Actual</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	2
<i>Non-Default (0)</i>	1	144
<i>Total</i>	2	146

Size = 2

Data Training

<i>Predicted</i>	<i>Actual</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	217
<i>Total</i>	2	218

Data Testing

<i>Predicted</i>	<i>Actual</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	110
<i>Total</i>	2	110

Size = 3

Data Training

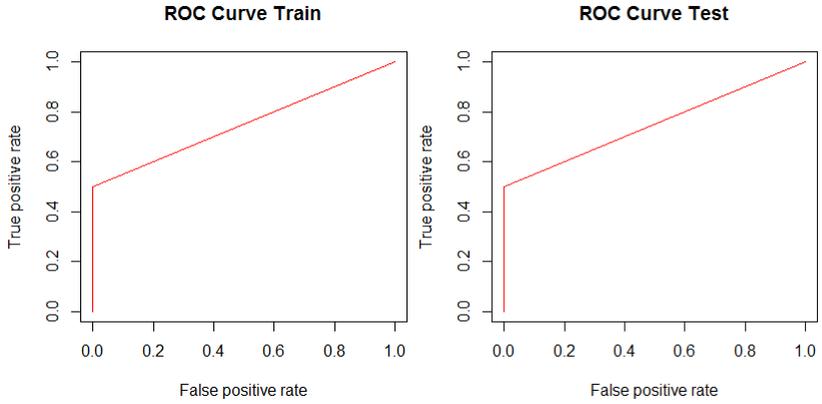
<i>Predicted</i>	<i>Actual</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	145
<i>Total</i>	2	145

Data Testing

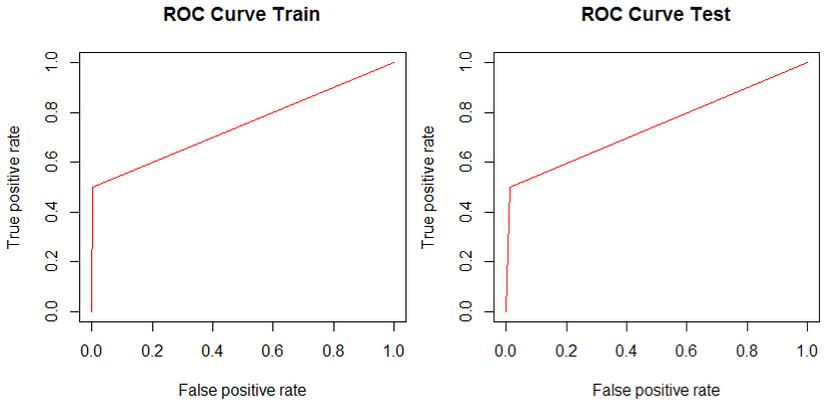
<i>Predicted</i>	<i>Actual</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	72
<i>Total</i>	2	73

Lampiran 8. Kurva ROC Klasifikasi dengan Metode Analisis Diskriminan Linier

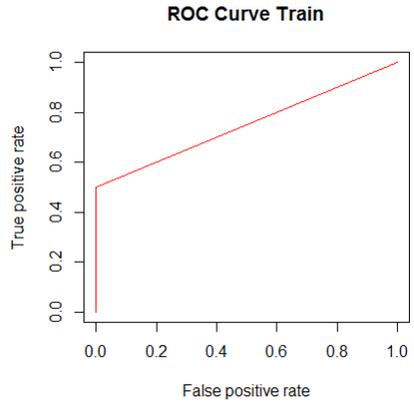
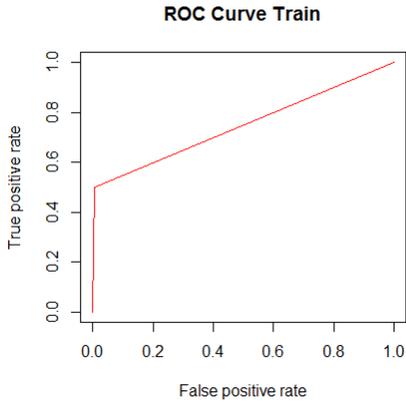
Size = 0



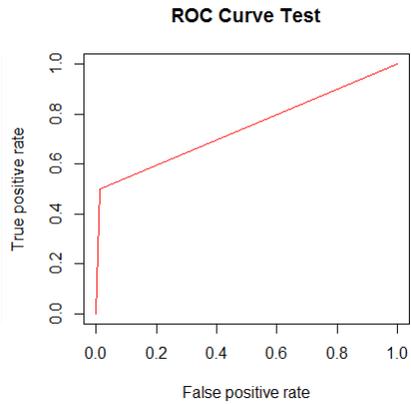
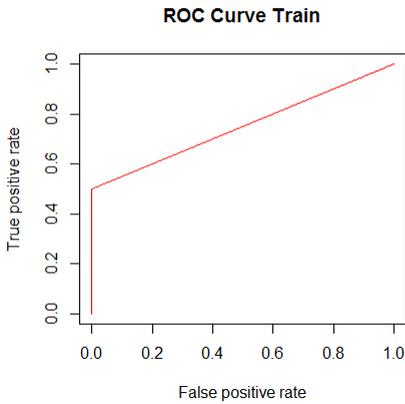
Size = 1



Size = 2



Size = 3



Lampiran 9. Variabel Terpilih Pada Analisis Diskriminan
Stepwise

Size = 0

Variables in the Analysis

Step		Tolerance	Sig. of F to Remove	Wilks' Lambda
1	BOPO	1.000	.000	
2	BOPO	.886	.000	1.000
	ATTM	.886	.000	.465
3	BOPO	.683	.000	.905
	ATTM	.882	.000	.449
	ROA	.732	.002	.434
4	BOPO	.311	.000	.472
	ATTM	.859	.000	.430
	ROA	.706	.000	.426
	ROE	.337	.001	.422

Size = 1

Variables in the Analysis

<i>Step</i>		Tolerance	Sig. of F to Remove	Wilks' Lambda
1	ROE	1.000	.000	
2	ROE	.600	.000	.991
	ROA	.600	.002	.869
3	ROE	.488	.000	.860
	ROA	.550	.000	.849
	BOPO	.546	.000	.841

Size = 2

Variables in the Analysis

<i>Step</i>		Tolerance	Sig. of F to Remove	Wilks' Lambda
1	ROE	1.000	.000	
2	ROE	.553	.000	.996
	ROA	.553	.007	.913
3	ROE	.512	.000	.899
	ROA	.472	.000	.895
	BOPO	.576	.001	.883

Size = 3

Variables in the Analysis

<i>Step</i>	Tolerance	Sig. of F to Remove
1 ROA	1.000	.000

Lampiran 10. *Confusion Matrix Analisis Diskriminan Stepwise*

Size = 0

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	182
<i>Total</i>	2	183

Size = 1

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	291
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	2
<i>Non-Default (0)</i>	1	144
<i>Total</i>	2	146

Size = 2

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	2
<i>Non-Default (0)</i>	1	216
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	110
<i>Total</i>	2	110

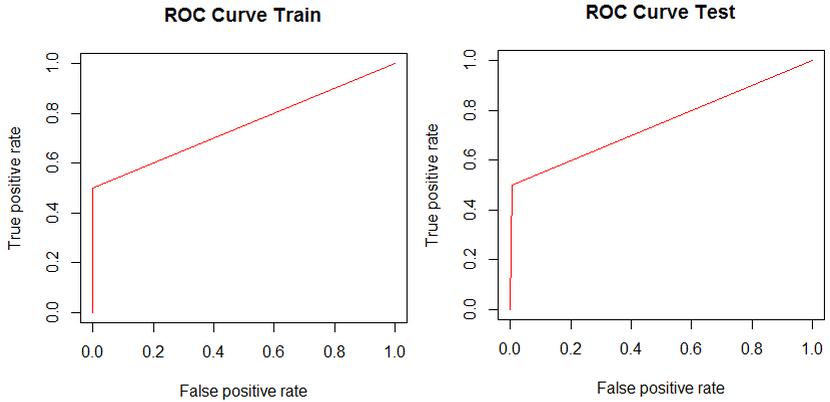
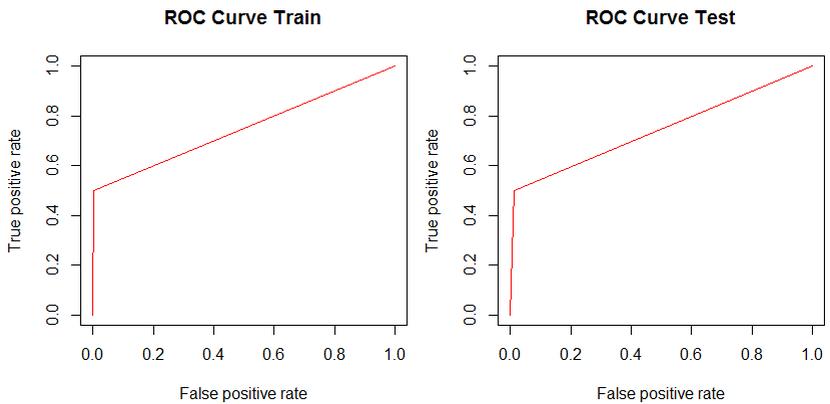
Size = 3

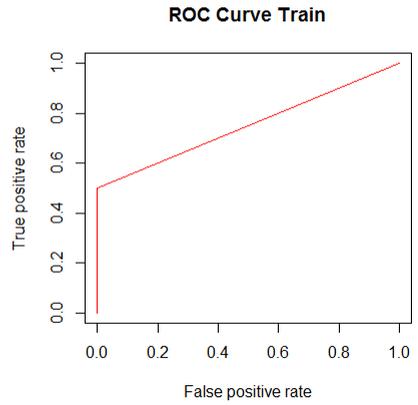
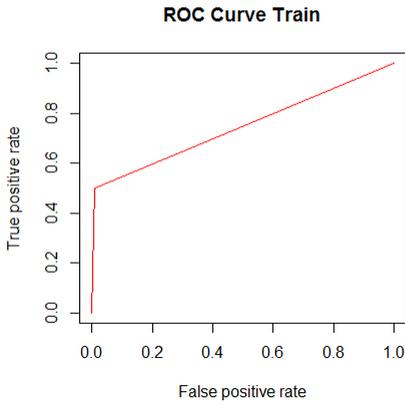
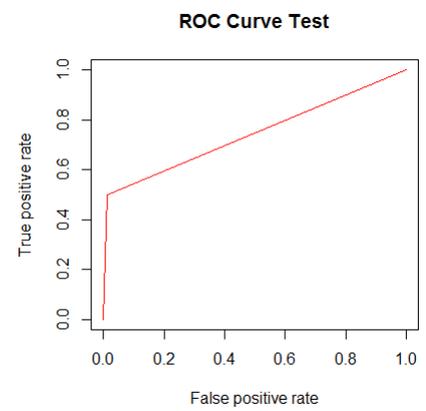
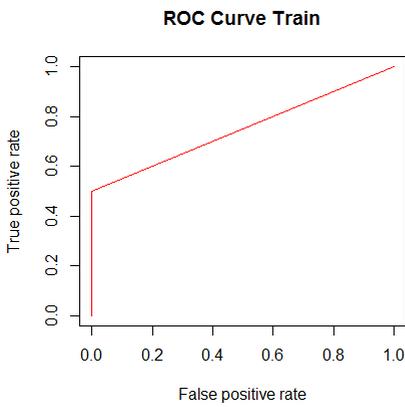
Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	72
<i>Total</i>	2	73

Lampiran 11. Kurva ROC Analisis Diskriminan *Stepwise**Size = 0**Size = 1*

$Size = 2$  $Size = 3$ 

Lampiran 12. *Confusion Matrix* Analisis Diskriminan
Univariat $Size = 0$

LDR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

ROA

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	364
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	182
<i>Total</i>	2	183

ROE

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	183
<i>Total</i>	2	183

NIM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	364
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	183
<i>Total</i>	2	183

BOPO

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	182
<i>Total</i>	2	183

Aktiva Produk Bermasalah

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	3
<i>Non-Default (0)</i>	1	362
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	183
<i>Total</i>	2	183

NPL

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	<i>1</i>	<i>6</i>
<i>Non-Default (0)</i>	<i>1</i>	<i>359</i>
<i>Total</i>	<i>2</i>	<i>365</i>

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	<i>1</i>	<i>1</i>
<i>Non-Default (0)</i>	<i>1</i>	<i>182</i>
<i>Total</i>	<i>2</i>	<i>183</i>

PPAP Terhadap Aktiva Produktif

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	<i>1</i>	<i>3</i>
<i>Non-Default (0)</i>	<i>1</i>	<i>362</i>
<i>Total</i>	<i>2</i>	<i>365</i>

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	<i>1</i>	<i>0</i>
<i>Non-Default (0)</i>	<i>1</i>	<i>183</i>
<i>Total</i>	<i>2</i>	<i>183</i>

Pemenuhan PPAP

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

CAR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

ATTM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

Inflasi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

Pertumbuhan Ekonomi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

Lampiran 13. Uji Signifikansi Parameter Analisis
Diskriminan Univariat *Size* = 0

	Df	Sum Sq	Mean Sq	F Value	Pr(>F)
LDR	1	365	365	3.66E+34	<2e-16
ROA	1	401	401	7.30E+34	<2e-16
ROE	1	743.5	743.5	2.79E+34	<2e-16
NIM	1	379.2	379.2	3.77E+33	<2e-16
BOPO	1	784.1	784.1	4.59E+34	<2e-16
Aktiva Produktif	1	427.2	427.2	1.12E+34	<2e-16
Bermasalah					
NPL	1	387.3	387.3	2.91E+34	<2e-16
PPAP Terhadap Aktiva Produktif	1	394.1	394.1	4.86E+33	<2e-16
Pemenuhan PPAP	1	365.4	365.4	2.63E+33	<2e-16
CAR	1	366.9	366.9	7.96E+33	<2e-16
ATTM	1	365	365	1.68E+34	<2e-16
Infalsi	1	365.2	365.2	2.02E+33	<2e-16
Pertumbuhan Ekonomi	1	366.5	366.5	1.59E+33	<2e-16

Lampiran 14. *Confusion Matrix* Analisis Diskriminan
Univariat Size = 1

LDR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

ROA

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	2
<i>Non-Default (0)</i>	2	290
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

ROE

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	3
<i>Non-Default (0)</i>	1	289
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	2
<i>Non-Default (0)</i>	1	144
<i>Total</i>	2	146

NIM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	146
<i>Total</i>	2	146

BOPO

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	2
<i>Non-Default (0)</i>	1	290
<i>Total</i>	2	292

Data Testing

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	1	1
<i>Non-Default</i> (0)	1	145
<i>Total</i>	2	146

Aktiva Produk Bermasalah

Data Training

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	0	2
<i>Non-Default</i> (0)	2	290
<i>Total</i>	2	292

Data Testing

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	0	1
<i>Non-Default</i> (0)	2	145
<i>Total</i>	2	146

NPL

Data Training

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	1	2
<i>Non-Default</i> (0)	1	290
<i>Total</i>	2	292

Data Testing

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	1	1
<i>Non-Default</i> (0)	1	145
<i>Total</i>	2	146

PPAP Terhadap Aktiva Produktif

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

Pemenuhan PPAP

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

CAR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

ATTM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	146

Inflasi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

Pertumbuhan Ekonomi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

Lampiran 15. *Confusion Matrix* Analisis Diskriminan
Univariat Size = 2

LDR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

ROA

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	2
<i>Non-Default (0)</i>	2	216
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

ROE

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	3
<i>Non-Default (0)</i>	1	215
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	110
<i>Total</i>	2	110

NIM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

BOPO

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	2
<i>Non-Default (0)</i>	1	216
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	110
<i>Total</i>	2	110

Aktiva Produk Bermasalah

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	217
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

NPL

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	2
<i>Non-Default (0)</i>	2	216
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

PPAP Terhadap Aktiva Produktif

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

Pemenuhan PPAP

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

CAR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

ATTM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	217
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	109
<i>Total</i>	2	110

Inflasi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

Pertumbuhan Ekonomi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

Lampiran 16. Confusion Matrix Analisis Diskriminan
Univariat Size = 3

LDR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

ROA

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	72
<i>Total</i>	2	73

ROE

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	144
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	72
<i>Total</i>	2	73

NIM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

BOPO

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	145
<i>Total</i>	2	145

Data Testing

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	1	1
<i>Non-Default</i> (0)	1	72
<i>Total</i>	2	73

Aktiva Produk Bermasalah

Data Training

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	0	0
<i>Non-Default</i> (0)	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	0	0
<i>Non-Default</i> (0)	2	73
<i>Total</i>	2	73

NPL

Data Training

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	0	1
<i>Non-Default</i> (0)	2	144
<i>Total</i>	2	145

Data Testing

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	0	0
<i>Non-Default</i> (0)	2	73
<i>Total</i>	2	73

PPAP Terhadap Aktiva Produktif

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

Pemenuhan PPAP

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

CAR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

ATTM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

Inflasi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

Pertumbuhan Ekonomi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

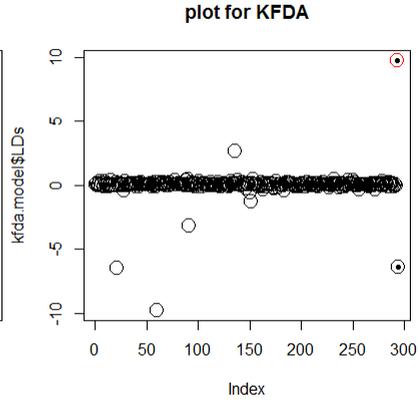
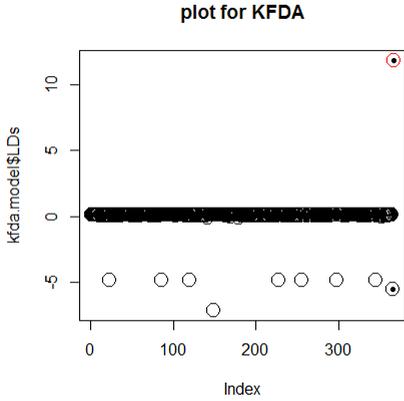
Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

Lampiran 17. Kernel Fisher Discriminant Plot

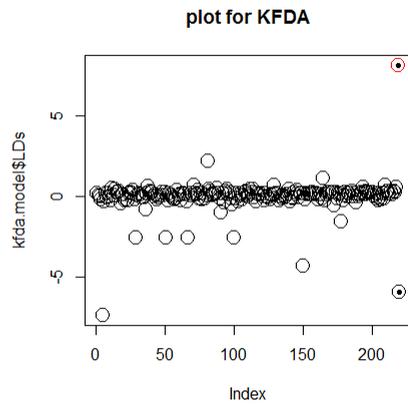
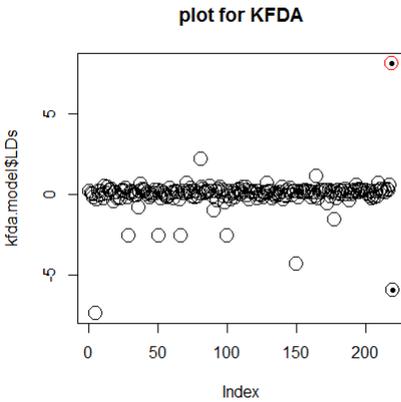
Size = 0

Size = 1



Size = 2

Size = 3



Lampiran 18. *Confussion Matrix* Klasifikasi dengan Metode Analisis Diskriminan Kernel

Size = 0

Data Training

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	1	0
<i>Non-Default</i> (0)	1	365
<i>Total</i>	2	365

Data Testing

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	1	0
<i>Non-Default</i> (0)	1	183
<i>Total</i>	2	183

Size = 1

Data Training

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	1	0
<i>Non-Default</i> (0)	1	292
<i>Total</i>	2	292

Data Testing

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	1	0
<i>Non-Default</i> (0)	1	146
<i>Total</i>	2	146

Size = 2

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	110
<i>Total</i>	2	110

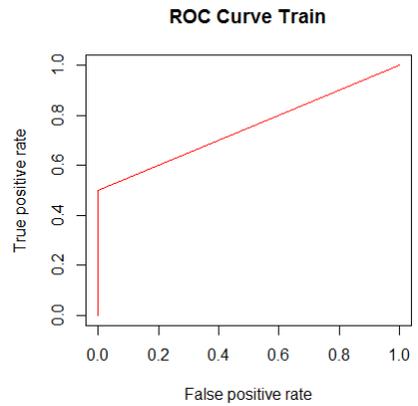
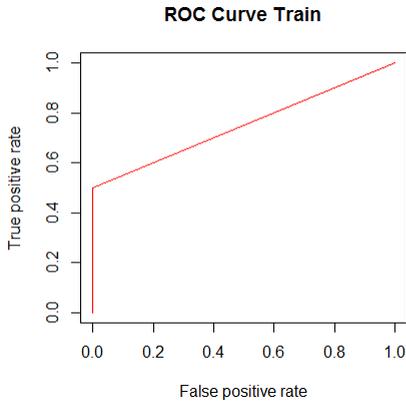
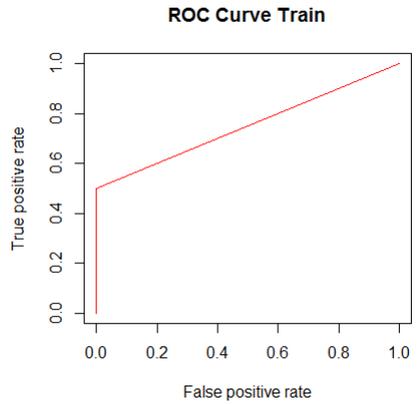
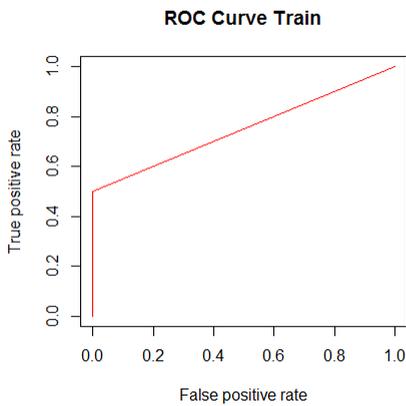
Size = 3

Data Training

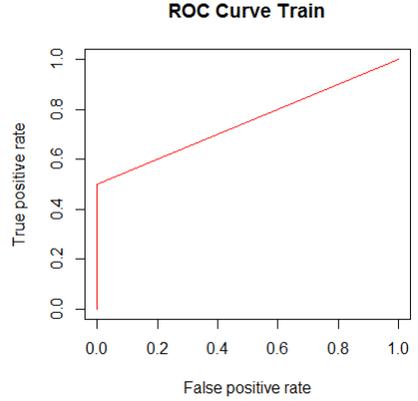
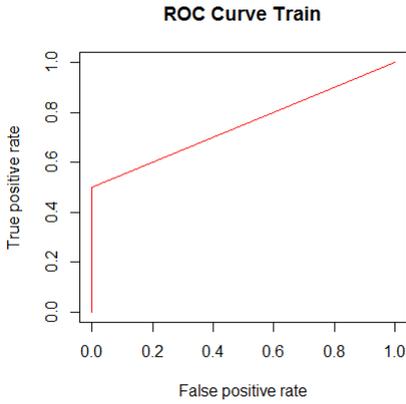
<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	145
<i>Total</i>	2	145

Data Testing

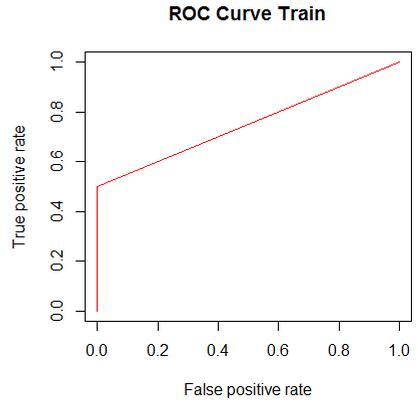
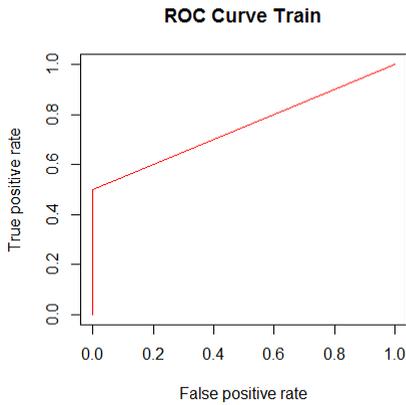
<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	73
<i>Total</i>	2	73

Lampiran 19. Kurva ROC Klasifikasi dengan Metode Analisis Diskriminan Kernel*Size = 0**Size = 1*

Size = 2



Size = 3



Lampiran 20. Estimasi Parameter Model Prediksi *Financial Distress* dengan Regresi Logistik Biner

Size = 0

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-1.17E+02	1.73E+05	-0.001	0.999
x1	4.62E-03	4.82E+01	0	1
x2	1.06E+00	3.92E+03	0	1
x3	3.00E-01	4.52E+02	0.001	0.999
x4	2.45E-02	1.24E+03	0	1
x5	4.53E-01	2.47E+02	0.002	0.999
x6	5.28E-01	2.53E+03	0	1
x7	5.63E-02	1.13E+03	0	1
x8	-2.15E+00	5.58E+03	0	1
x9	-8.94E-03	1.79E+02	0	1
x10	2.87E-02	2.29E+02	0	1
x11	-1.94E-01	4.47E+02	0	1
x12	3.18E-01	1.52E+03	0	1
x13	9.21E-01	2.31E+04	0	1

Size = 1

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-3.12E+02	2.69E+05	-0.001	0.999
x1	1.27E-02	4.60E+01	0	1
x2	4.83E-01	6.31E+02	0.001	0.999
x3	-4.81E-01	3.36E+02	-0.001	0.999
x4	4.09E-01	3.04E+03	0	1
x5	-2.50E-01	6.38E+02	0	1
x6	-9.30E+00	5.01E+03	-0.002	0.999
x7	6.33E+00	2.46E+03	0.003	0.998
x8	-9.76E+00	7.34E+03	-0.001	0.999
x9	7.11E-02	7.69E+01	0.001	0.999
x10	-3.35E-01	3.32E+02	-0.001	0.999
x11	4.34E-02	2.39E+02	0	1
x12	1.15E+00	2.68E+03	0	1
x13	5.33E+01	2.51E+04	0.002	0.998

Size = 2

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-1.99E+02	3.30E+05	-0.001	1
x1	6.21E-03	8.57E+01	0	1
x2	2.22E+00	1.77E+04	0	1
x3	1.68E-01	5.07E+02	0	1
x4	-8.18E-01	1.83E+03	0	1
x5	6.79E-01	1.07E+03	0.001	0.999
x6	-2.06E+00	6.28E+03	0	1
x7	1.74E+00	2.28E+03	0.001	0.999
x8	-2.62E+00	6.84E+03	0	1
x9	6.73E-02	1.46E+02	0	1
x10	-1.05E-01	5.62E+02	0	1
x11	3.41E-02	2.38E+02	0	1
x12	-4.64E-01	2.78E+03	0	1
x13	7.60E+00	5.83E+04	0	1

Size = 3

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-2.57E+01	2.02E+05	0	1
x1	8.97E-03	2.45E+01	0	1
x2	2.28E-02	5.68E+02	0	1
x3	9.32E-02	5.05E+02	0	1
x4	-2.18E+00	2.90E+03	-0.001	0.999
x5	3.90E-01	5.95E+02	0.001	0.999
x6	3.56E+00	2.78E+03	0.001	0.999
x7	-5.90E-01	2.71E+03	0	1
x8	-4.18E+00	1.22E+04	0	1
x9	-3.11E-01	4.57E+02	-0.001	0.999
x10	8.39E-02	2.55E+02	0	1
x11	-2.93E-01	3.89E+02	-0.001	0.999
x12	1.75E+00	1.70E+03	0.001	0.999
x13	NA	NA	NA	NA

Lampiran 21. *Odds Ratio* Model Prediksi *Financial Distress* dengan Regresi Logistik Biner

Size = 0

	<i>Odds Ratio</i>
(Intercept)	0.000
LDR	1.005
ROA	2.889
ROE	1.350
NIM	1.025
BOPO	1.573
Aktiva Produktif Bermasalah	1.695
NPL	1.058
PPAP Terhadap Aktiva Produktif	0.116
Pemenuhan PPAP	0.991
CAR	1.029
ATTM	0.823
Inflasi	1.375
Pertumbuhan Ekonomi	2.511

Size = 1

	<i>Odds Ratio</i>
(Intercept)	0.000
LDR	1.013
ROA	1.620
ROE	0.618
NIM	1.505
BOPO	0.778
Aktiva Produktif Bermasalah	0.000
NPL	561.490
PPAP Terhadap Aktiva Produktif	0.000
Pemenuhan PPAP	1.074
CAR	0.715
ATTM	1.044
Inflasi	3.161
Pertumbuhan Ekonomi	13308310000000000000000.000

Size = 2

	<i>Odds Ratio</i>
(Intercept)	0.000
LDR	1.006
ROA	9.212
ROE	1.182
NIM	0.441
BOPO	1.972
Aktiva Produktif Bermasalah	0.127
NPL	5.707
PPAP Terhadap Aktiva Produktif	0.073
Pemenuhan PPAP	1.070
CAR	0.900
ATTM	1.035
Inflasi	0.629
Pertumbuhan Ekonomi	1988.283

Size = 3

	<i>Odds Ratio</i>
(Intercept)	0.000
LDR	1.009
ROA	1.023
ROE	1.098
NIM	0.113
BOPO	1.477
Aktiva Produktif Bermasalah	35.076
NPL	0.555
PPAP Terhadap Aktiva Produktif	0.015
Pemenuhan PPAP	0.732
CAR	1.087
ATTM	0.746
Inflasi	5.752
Pertumbuhan Ekonomi	NA

Lampiran 22. *Confussion Matrix* Klasifikasi dengan Metode Regresi Logistik Biner

Size = 0

Data Training

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	2	0
<i>Non-Default</i> (0)	0	365
<i>Total</i>	2	365

Data Testing

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	2	1
<i>Non-Default</i> (0)	0	182
<i>Total</i>	2	183

Size = 1

Data Training

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	2	0
<i>Non-Default</i> (0)	0	292
<i>Total</i>	2	292

Data Testing

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	2	0
<i>Non-Default</i> (0)	0	146
<i>Total</i>	2	146

Size = 2

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	2	0
<i>Non-Default (0)</i>	0	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	2	0
<i>Non-Default (0)</i>	0	110
<i>Total</i>	2	110

Size = 3

Data Training

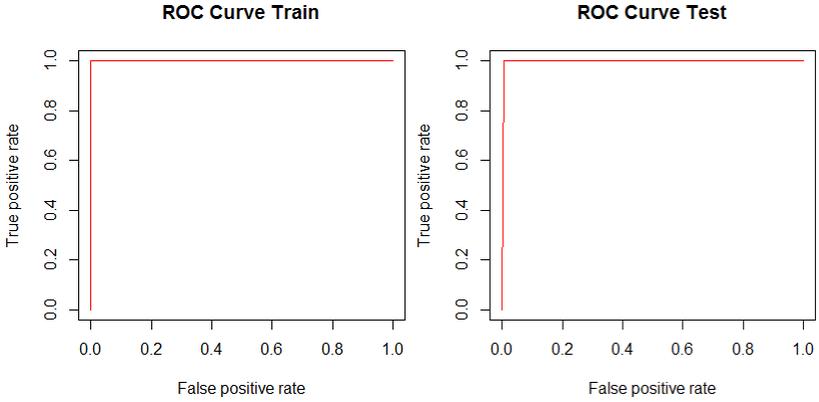
<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	2	0
<i>Non-Default (0)</i>	0	145
<i>Total</i>	2	145

Data Testing

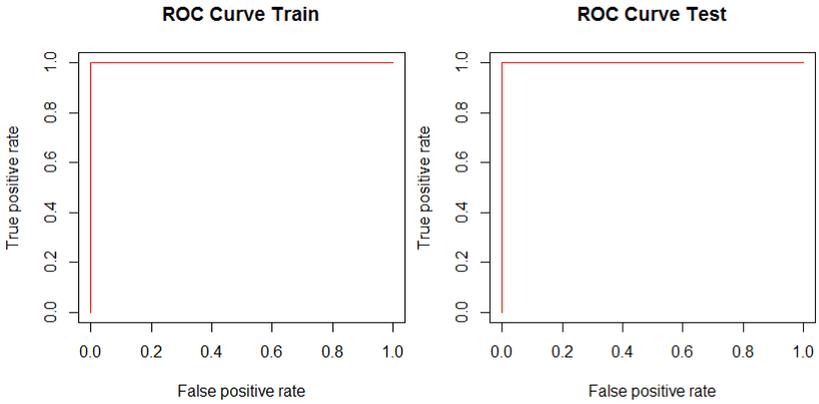
<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	2	3
<i>Non-Default (0)</i>	0	70
<i>Total</i>	2	73

Lampiran 23. Kurva ROC Klasifikasi dengan Metode Regresi Logistik Biner

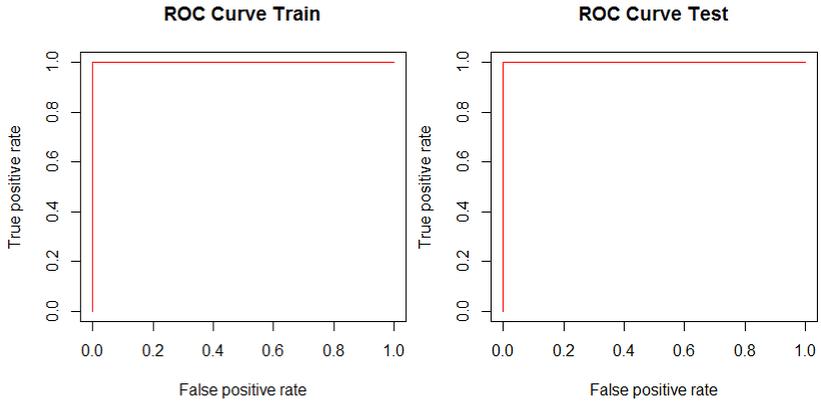
Size = 0



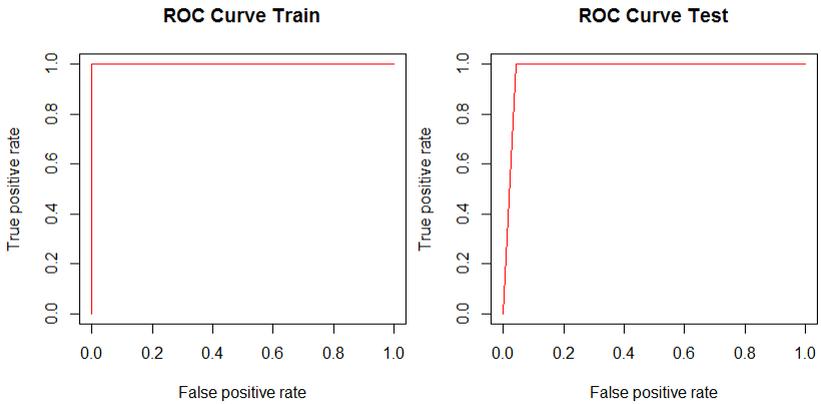
Size = 1

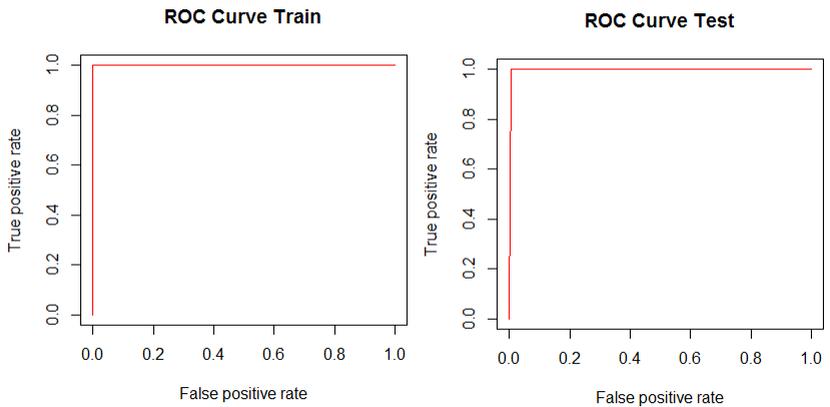
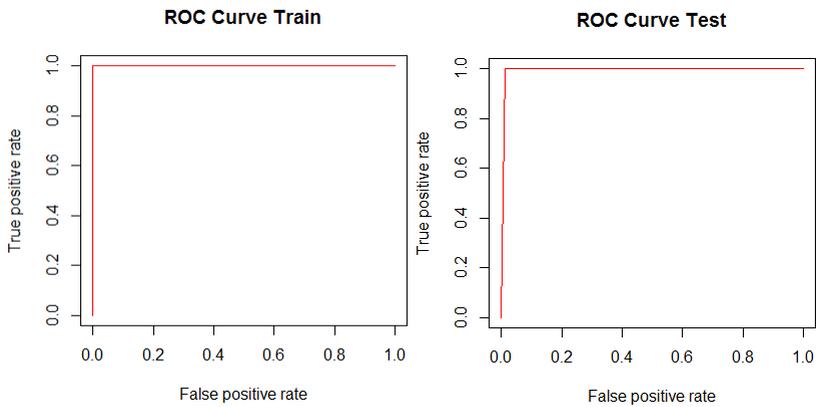


Size = 2

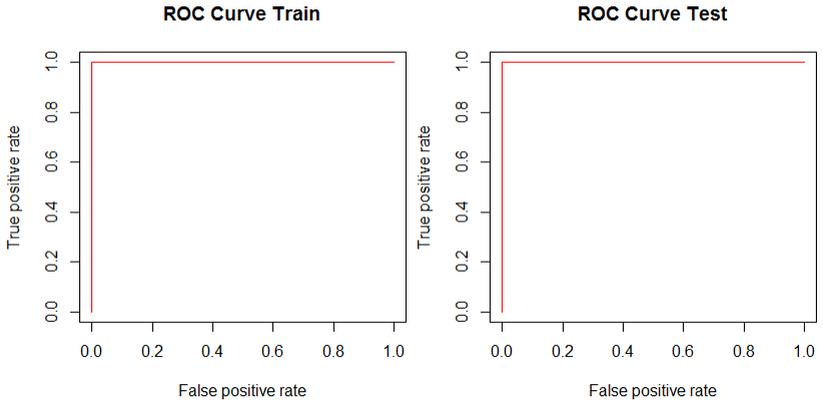


Size = 3

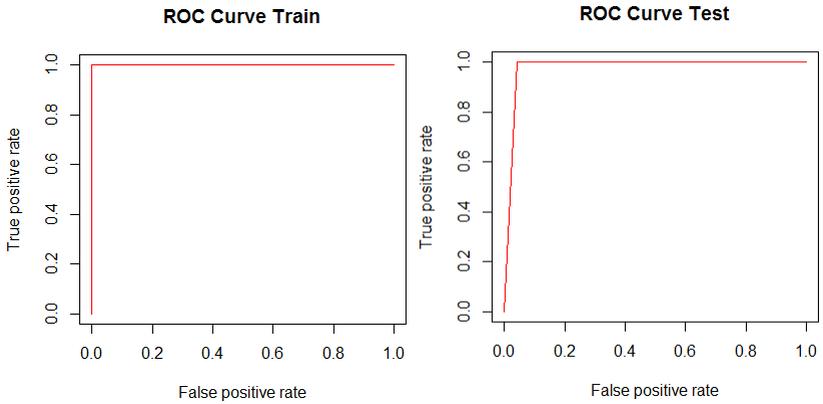


Lampiran 24. Kurva ROC Regresi Logistik *Stepwise Size = 0**Size = 0**Size = 1*

Size = 2



Size = 3



Lampiran 25. Confusion Matrix Regresi Logistik Univariat
Size = 0

LDR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

ROA

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	182
<i>Total</i>	2	183

ROE

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	183
<i>Total</i>	2	183

NIM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	364
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	183
<i>Total</i>	2	183

BOPO

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	364
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	182
<i>Total</i>	2	183

Aktiva Produk Bermasalah

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	364
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

NPL

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

PPAP Terhadap Aktiva Produktif

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

Pemenuhan PPAP

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

CAR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	183
<i>Total</i>	2	183

ATTM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

Inflasi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

Pertumbuhan Ekonomi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Lampiran 26. *Confusion Matrix* Regresi Logistik Univariat
Size = 1

LDR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

ROA

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

ROE

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	146
<i>Total</i>	2	146

NIM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	146
<i>Total</i>	2	146

BOPO

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	146
<i>Total</i>	2	146

Aktiva Produktif Bermasalah

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

NPL

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

PPAP Terhadap Aktiva Produktif

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

Pemenuhan PPAP

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

CAR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

ATTM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

Inflasi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

Pertumbuhan Ekonomi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

Lampiran 27. Confusion Matrix Regresi Logistik Univariat
Size = 2

LDR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

ROA

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

ROE

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

NIM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	110
<i>Total</i>	2	110

BOPO

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

Aktiva Produk Bermasalah

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

NPL

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

PPAP Terhadap Aktiva Produktif

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

Pemenuhan PPAP

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

CAR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

ATTM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

Inflasi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

Pertumbuhan Ekonomi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

Lampiran 28. *Confusion Matrix* Regresi Logistik Univariat
Size = 3

LDR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

ROA

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	72
<i>Total</i>	2	73

ROE

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	72
<i>Total</i>	2	73

NIM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	72
<i>Total</i>	2	73

BOPO

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	72
<i>Total</i>	2	73

Aktiva Produk Bermasalah

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

NPL

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

PPAP Terhadap Aktiva Produktif

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

Pemenuhan PPAP

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

CAR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

ATTM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

Inflasi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

Pertumbuhan Ekonomi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

Lampiran 29. Perbandingan Nilai Log-Likelihood untuk Parameter τ

Untuk size = 0

τ	Log likelihood	τ	Log likelihood
0.01	0.01903826	-0.01	5.346834e-12
0.02	4.156009e-08	-0.02	0
0.03	5.113489e-07	-0.03	0
0.04	1.981411e-08	-0.04	0
0.05	1.516542e-08	-0.05	0
0.06	12.24807	-0.06	0
0.07	5.005455e-09	-0.07	0
0.08	2.875511e-08	-0.08	0
0.09	0	-0.09	0
0.1	9.724724e-09	-0.10	0
0	0		

Lampiran 30. Estimasi Parameter Model Prediksi
Financial Distress dengan GEVR

Size = 0

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-3.83E+01	1.88E+02	-0.203	0.839
x1	-2.32E-03	2.90E-02	-0.08	0.936
x2	-5.64E-02	1.93E-01	-0.293	0.77
x3	1.04E-01	1.27E-01	0.818	0.414
x4	-2.66E-01	1.69E+00	-0.157	0.875
x5	7.64E-02	1.96E-01	0.39	0.697
x6	-1.47E-01	4.45E+00	-0.033	0.974
x7	1.56E-01	2.18E+00	0.071	0.943
x8	-5.84E-02	1.66E+00	-0.035	0.972
x9	-7.33E-04	8.26E-01	-0.001	0.999
x10	4.01E-02	7.11E-01	0.056	0.955
x11	1.80E-02	2.72E-01	0.066	0.947
x12	-1.56E-01	3.39E+00	-0.046	0.963
x13	2.92E+00	3.38E+01	0.087	0.931

Size = 1

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-26.1143	19.82684	-1.317	0.1878
x1	0.002597	0.002041	1.272	0.2032
x2	0.019518	0.091672	0.213	0.8314
x3	-0.01164	0.07306	-0.159	0.8734
x4	-0.14154	0.30615	-0.462	0.6438
x5	0.004026	0.04996	0.081	0.9358
x6	-0.43648	0.184009	-2.372	0.0177
x7	0.304829	0.221071	1.379	0.1679
x8	-0.36031	0.441535	-0.816	0.4145
x9	0.006257	0.015197	0.412	0.6805
x10	-0.04064	0.029957	-1.357	0.1749
x11	-0.00173	0.027026	-0.064	0.9489
x12	-0.52011	0.989417	-0.526	0.5991
x13	4.551401	2.321323	1.961	0.0499

Size = 2

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-40.2975	117.3252	-0.343	0.731
x1	-0.00172	0.008509	-0.202	0.84
x2	0.178171	2.527169	0.071	0.944
x3	0.02606	0.182232	0.143	0.886
x4	-0.20678	0.791097	-0.261	0.794
x5	0.11724	0.183318	0.64	0.522
x6	-0.38764	0.774444	-0.501	0.617
x7	0.216208	0.547065	0.395	0.693
x8	-0.06004	0.583109	-0.103	0.918
x9	0.013033	0.025401	0.513	0.608
x10	-0.00739	0.107807	-0.069	0.945
x11	0.012186	0.092106	0.132	0.895
x12	-0.12768	1.359361	-0.094	0.925
x13	2.723508	19.00905	0.143	0.886

Size = 3

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-3.06328	13.95194	-0.22	0.8262
x1	-0.00456	0.007267	-0.627	0.5306
x2	1.108566	1.3786	0.804	0.4213
x3	-0.02408	0.083163	-0.29	0.7721
x4	-0.41007	0.400776	-1.023	0.3062
x5	0.117185	0.056254	2.083	0.0372
x6	0.300782	0.43911	0.685	0.4934
x7	-0.18961	0.26491	-0.716	0.4741
x8	-0.2412	0.166363	-1.45	0.1471
x9	-0.02095	0.017692	-1.184	0.2365
x10	0.015899	0.206475	0.077	0.9386
x11	-0.02621	0.098959	-0.265	0.7912
x12	0.555919	0.621934	0.894	0.3714
x13	-3.73893	5.234429	-0.714	0.475

Lampiran 31. *Confussion Matrix* Klasifikasi dengan Metode GEVR

Size = 0

Data Training

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	2	0
<i>Non-Default</i> (0)	0	365
<i>Total</i>	2	365

Data Testing

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	2	3
<i>Non-Default</i> (0)	0	180
<i>Total</i>	2	183

Size = 1

Data Training

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	2	0
<i>Non-Default</i> (0)	0	292
<i>Total</i>	2	292

Data Testing

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	2	3
<i>Non-Default</i> (0)	0	143
<i>Total</i>	2	146

Size = 2

Data Training

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	2	0
<i>Non-Default</i> (0)	0	218
<i>Total</i>	2	218

Data Testing

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	2	3
<i>Non-Default</i> (0)	0	107
<i>Total</i>	2	110

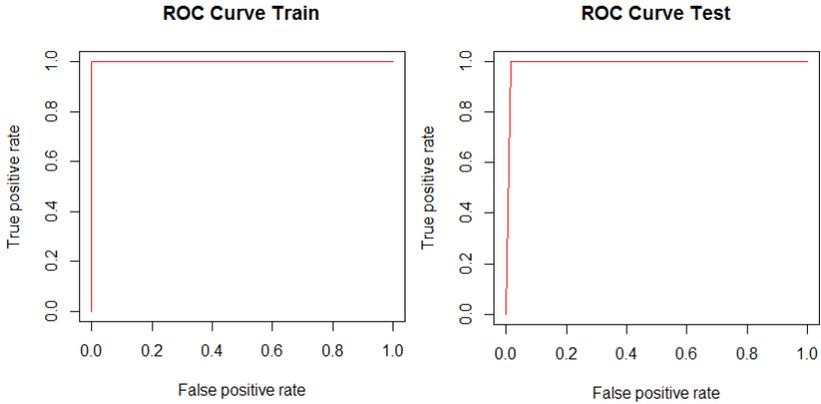
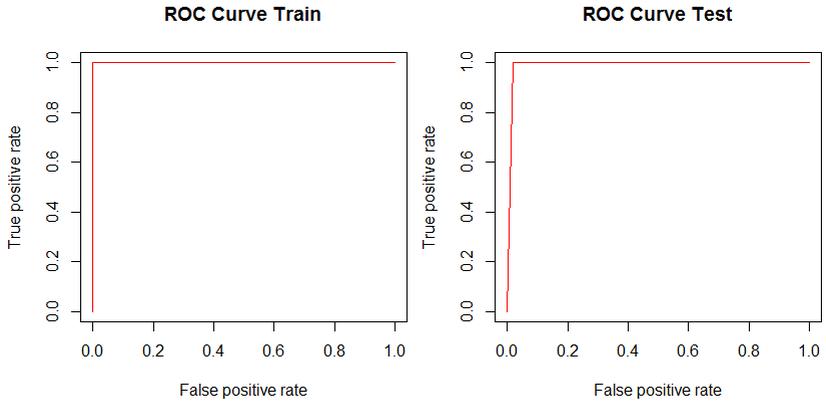
Size = 3

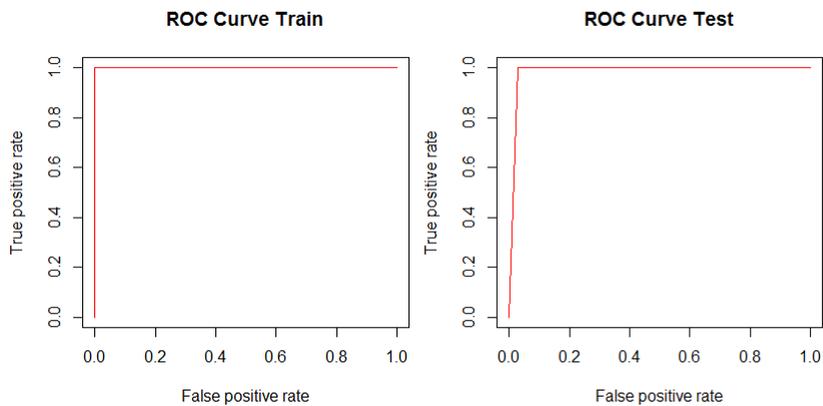
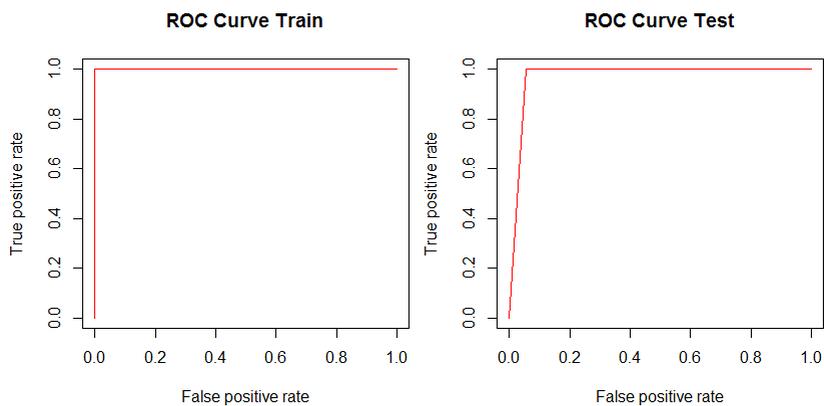
Data Training

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	2	0
<i>Non-Default</i> (0)	0	145
<i>Total</i>	2	145

Data Testing

<i>Predicted</i> (\hat{Y})	<i>Actual</i> (Y)	
	<i>Default</i> (1)	<i>Non-Default</i> (0)
<i>Default</i> (1)	2	4
<i>Non-Default</i> (0)	0	69
<i>Total</i>	2	73

Lampiran 32. Kurva ROC Klasifikasi dengan Metode GEVR*Size = 0**Size = 1*

Size = 2*Size = 3*

Lampiran 33. Confusion Matrix GEVR Stepwise

Size = 0

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	42
<i>Non-Default (0)</i>	2	250
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	21
<i>Non-Default (0)</i>	2	125
<i>Total</i>	2	146

Size = 1

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	364
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	183
<i>Total</i>	2	183

Size = 2

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	2
<i>Non-Default (0)</i>	2	216
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

Size = 3

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	3
<i>Non-Default (0)</i>	2	142
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

Lampiran 34. Confusion Matrix GEVR Univariat Size = 0

LDR

Data Training

Predicted (\hat{Y})	Actual (Y)	
	Default (1)	Non-Default (0)
Default (1)	0	0
Non-Default (0)	2	365
Total	2	365

Data Testing

Predicted (\hat{Y})	Actual (Y)	
	Default (1)	Non-Default (0)
Default (1)	0	0
Non-Default (0)	2	183
Total	2	183

ROA

Data Training

Predicted (\hat{Y})	Actual (Y)	
	Default (1)	Non-Default (0)
Default (1)	0	1
Non-Default (0)	2	364
Total	2	365

Data Testing

Predicted (\hat{Y})	Actual (Y)	
	Default (1)	Non-Default (0)
Default (1)	0	1
Non-Default (0)	2	182
Total	2	183

ROE

Data Training

Predicted (\hat{Y})	Actual (Y)	
	Default (1)	Non-Default (0)
Default (1)	1	1
Non-Default (0)	1	364
Total	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	<i>1</i>	<i>0</i>
<i>Non-Default (0)</i>	<i>1</i>	<i>183</i>
<i>Total</i>	<i>2</i>	<i>183</i>

NIM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	<i>1</i>	<i>1</i>
<i>Non-Default (0)</i>	<i>1</i>	<i>364</i>
<i>Total</i>	<i>2</i>	<i>365</i>

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	<i>1</i>	<i>0</i>
<i>Non-Default (0)</i>	<i>1</i>	<i>183</i>
<i>Total</i>	<i>2</i>	<i>183</i>

BOPO

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	<i>1</i>	<i>1</i>
<i>Non-Default (0)</i>	<i>1</i>	<i>364</i>
<i>Total</i>	<i>2</i>	<i>365</i>

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	<i>1</i>	<i>1</i>
<i>Non-Default (0)</i>	<i>1</i>	<i>182</i>
<i>Total</i>	<i>2</i>	<i>183</i>

Aktiva Produk Bermasalah

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	364
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

NPL

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	364
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

PPAP Terhadap Aktiva Produktif

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	2
<i>Non-Default (0)</i>	2	363
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

Pemenuhan PPAP

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

CAR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	364
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	182
<i>Total</i>	2	183

ATTM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

Inflasi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	183
<i>Total</i>	2	183

Pertumbuhan Ekonomi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	365
<i>Total</i>	2	365

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	<i>0</i>	<i>0</i>
<i>Non-Default (0)</i>	<i>2</i>	<i>183</i>
<i>Total</i>	<i>2</i>	<i>183</i>

Lampiran 35. Confusion Matrix GEVR Univariat Size = 1

LDR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

ROA

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	2
<i>Non-Default (0)</i>	2	290
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

ROE

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	146
<i>Total</i>	2	146

NIM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	146
<i>Total</i>	2	146

BOPO

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	146
<i>Total</i>	2	146

Aktiva Produk Bermasalah

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	291
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	146

NPL

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	291
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

PPAP Terhadap Aktiva Produktif

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

Pemenuhan PPAP

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

CAR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

ATTM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	146

Inflasi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

Pertumbuhan Ekonomi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	292
<i>Total</i>	2	292

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	146
<i>Total</i>	2	146

Lampiran 36. Confusion Matrix GEVR Univariat Size = 2

LDR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

ROA

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

ROE

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	109
<i>Total</i>	2	110

NIM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	110
<i>Total</i>	2	110

BOPO

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	217
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

Aktiva Produk Bermasalah

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	217
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

NPL

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

PPAP Terhadap Aktiva Produktif

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	2
<i>Non-Default (0)</i>	2	216
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

Pemenuhan PPAP

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

CAR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

ATTM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

Inflasi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

Pertumbuhan Ekonomi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	218
<i>Total</i>	2	218

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	110
<i>Total</i>	2	110

Lampiran 37. Confusion Matrix GEVR Univariat Size = 3

LDR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

ROA

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

ROE

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	144
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	72
<i>Total</i>	2	73

NIM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	1
<i>Non-Default (0)</i>	2	144
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

BOPO

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	0
<i>Non-Default (0)</i>	1	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	1	1
<i>Non-Default (0)</i>	1	72
<i>Total</i>	2	73

Aktiva Produk Bermasalah

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

NPL

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

PPAP Terhadap Aktiva Produktif

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

Pemenuhan PPAP

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

CAR

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

ATTM

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

Inflasi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

Pertumbuhan Ekonomi

Data Training

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	145
<i>Total</i>	2	145

Data Testing

<i>Predicted (\hat{Y})</i>	<i>Actual (Y)</i>	
	<i>Default (1)</i>	<i>Non-Default (0)</i>
<i>Default (1)</i>	0	0
<i>Non-Default (0)</i>	2	73
<i>Total</i>	2	73

Lampiran 38. *Syntax* Uji Homogenitas Matrix Varians
Konvarian

```
library(biotools)

data<-read.csv("D:/Bismilah TA/data/DATA UJI.csv",
sep=";", header=TRUE)
head(data)

Uji_Homogen<-boxM(data[,-14], data[,14])
Uji_Homogen
```

Lampiran 39. *Syntax* Uji Normal Multivariat

```
library(MVN)

data<-read.csv("D:/Bismilah TA/data/DATA UJI.csv",
sep=";", header=TRUE)
head(data)

Uji_Norm<-mardiaTest(data[,-14], cov = TRUE, qqplot =
TRUE)
Uji_Norm
```

Lampiran 40. *Syntax* Uji Beda Rata-Rata Antar Kelompok

```
data<-read.csv("D:/Bismilah TA/data/DATA UJI.csv",  
sep=";", header=TRUE)  
head(data)
```

```
library(Discriminer)
```

```
Wilks = discPower(data[,-14], data[,14])
```

```
Wilks
```

Lampiran 41. *Syntax Partisi Data Training dan Data Testing*

```
rm(list=ls(all=TRUE))

Data1<-read.csv("D:/Bismilah TA/data/Training
Testing/FM training0.csv", sep=";", header=TRUE)
Data2<-read.csv("D:/Bismilah TA/data/Training
Testing/FM 0.csv", sep=";", header=TRUE)

library(data.table)
library(caret)
library(rpart)
library(rminer)

H=holdout(Data2$KONDISI.FD, ratio = 2/3)
dftrain=Data2[H$str,]
dftest=Data2[H$ts,]
nrow(dftrain);nrow(dftest)
datatrain<-rbind(dftrain, Data1)
datatest<-rbind(dftest, Data1)
head(datatrain)
head(datatest)

write.csv(datatrain,"D:/Bismilah TA/data/Training
Testing/datatrain3.csv")
write.csv(datatest,"D:/Bismilah TA/data/Training
Testing/datatest3.csv")
```

Lampiran 42. *Syntax* Analisis Diskriminan Linier

```

rm(list=ls(all=TRUE))

datatrain_x = read.csv("D:/Bismilah TA/data/Training
Testing/datatrain0.csv", sep="," , header=TRUE)
datatest_x = read.csv("D:/Bismilah TA/data/Training
Testing/datatest0.csv", sep="," , header=TRUE)
datatrain = datatrain_x[,-1]
datatest = datatest_x[,-1]

library(data.table)
library(caret)
library(pROC)
library(ROCR)
library(kernlab)
library(MASS)

model = lda(datatrain$KONDISI.FD~ ., datatrain)

pred.train1 = predict(model,datatrain)
pred.train2 = pred.train1$class
pred.train3 = as.matrix(pred.train2)
pred.train = as.numeric(pred.train3)
pred.test1 = predict(model, datatest)
pred.test2 = pred.test1$class
pred.test3 = as.matrix(pred.test2)
pred.test = as.numeric(pred.test3)

#confusion matrix & auc data train

hasil_train=confusionMatrix(table(pred.train,datatrain$KONDISI.FD))
aucdata_train=auc(datatrain$KONDISI.FD, pred.train)

```

```

train=cbind(hasil_train$overall[1],hasil_train$byClass[1],h
asil_train$byClass[2], aucdata_train)
  colnames(train)=c("accuracy","sensitivity","specificity",
"AUC")
  rownames(train)="Training"

#confusion matrix & auc data test

hasil_test=confusionMatrix(table(pred.test,datatest$KOND
ISI.FD))
  aucdata_test=auc(datatest$KONDISI.FD, pred.test)

test=cbind(hasil_test$overall[1],hasil_test$byClass[1],hasil
_test$byClass[2], aucdata_test)
  colnames(test)=c("accuracy","sensitivity","specificity",
"AUC")
  rownames(test)="Testing"

#ROC
  predtrain <- prediction(pred.train,
datatrain$KONDISI.FD)
  perftrain <- performance(predtrain, "tpr", "fpr")
  predtest <- prediction(pred.test, datatest$KONDISI.FD)
  perftest <- performance(predtest, "tpr", "fpr")

#output
  print(hasil_train)
  print(hasil_test)
  summary(model)
  print(train)
  print(test)
  win.graph()
  plot(perftrain, col="red", main="ROC Curve Train")
  win.graph()

```

```
plot(perftest, col="red", main="ROC Curve Test")
```

Lampiran 43. *Syntax* Analisis Diskriminan Kernel

```

rm(list=ls(all=TRUE))

datatrain_x = read.csv("D:/Bismilah TA/data/Training
Testing/datatrain2.csv", sep=",", header=TRUE)
datatest_x = read.csv("D:/Bismilah TA/data/Training
Testing/datatest2.csv", sep=",", header=TRUE)
datatrain = datatrain_x[,-1]
datatest = datatest_x[,-1]

library(data.table)
library(caret)
library(pROC)
library(ROCR)
library(kernlab)
library(MASS)
library(kfda)

kfda.model = kfda(trainData = datatrain,
kernel.name="rbfdot")
pred.train1 = kfda.predict(kfda.model, datatrain)
pred.train2 = pred.train1$class
pred.train3 = as.matrix(pred.train2)
pred.train = as.numeric(pred.train3)
pred.test1 = kfda.predict(kfda.model, datatest)
pred.test2 = pred.test1$class
pred.test3 = as.matrix(pred.test2)
pred.test = as.numeric(pred.test3)

plot(kfda.model$LDS, col=kfda.model$label, pch=20,
main="plot for KFDA")
points(pred.train1$x, col=pred.train1$class, cex=2)

#confusion matrix & auc data train

```

```

hasil_train=confusionMatrix(table(pred.train,datatrain$KONDISI.FD))
  aucdata_train=auc(datatrain$KONDISI.FD, pred.train)

train=cbind(hasil_train$overall[1],hasil_train$byClass[1],hasil_train$byClass[2], aucdata_train)
  colnames(train)=c("accuracy","sensitivity","specificity","AUC")
  rownames(train)="Training"

#confusion matrix & auc data test

hasil_test=confusionMatrix(table(pred.test,datatest$KONDISI.FD))
  aucdata_test=auc(datatest$KONDISI.FD, pred.test)

test=cbind(hasil_test$overall[1],hasil_test$byClass[1],hasil_test$byClass[2], aucdata_test)
  colnames(test)=c("accuracy","sensitivity","specificity","AUC")
  rownames(test)="Testing"

#ROC
  predtrain <- prediction(pred.train,
datatrain$KONDISI.FD)
  perfttrain <- performance(predtrain, "tpr", "fpr")
  predtest <- prediction(pred.test, datatest$KONDISI.FD)
  perfttest <- performance(predtest, "tpr", "fpr")

#output
  print(hasil_train)
  print(hasil_test)
  print(train)
  print(test)

```

```
summary(kfda.model)
win.graph()
plot(perftrain, col="red", main="ROC Curve Train")
win.graph()
plot(perftest, col="red", main="ROC Curve Test")
```

Lampiran 44. *Syntax* Regresi Logistik Biner

```

rm(list=ls(all=TRUE))

datatrain_x = read.csv("D:/Bismilah TA/data/Training
Testing/datatrain2.csv", sep=",", header=TRUE)
datatest_x = read.csv("D:/Bismilah TA/data/Training
Testing/datatest2.csv", sep=",", header=TRUE)
datatrain = datatrain_x[,-1]
datatest = datatest_x[,-1]

library(data.table)
library(caret)
library(pROC)
library(ROCR)

model=glm(KONDISI.FD~. , data=datatrain,
family=binomial(link='logit'), control=list(epsilon =1e-6))
OR=exp(coef(model))

#Prosedur Stepwise
#Modelstep=step(model)

pred.train=round(predict(model,datatrain[,-
14],type="response"))
pred.test=round(predict(model,datatest[,-
14],type="response"))
cm.train=table(actual=datatrain[,14],prediction=pred.train)
acc.train=round(sum(diag(cm.train))/sum(cm.train)*100,2)
cm.test=table(actual=datatest[,14],prediction=pred.test)
acc.test=round(sum(diag(cm.test))/sum(cm.test)*100,2)

#confusion matrix & auc data train

```

```

hasil_train=confusionMatrix(table(pred.train,datatrain$KONDISI.FD))
  aucdata_train=auc(datatrain$KONDISI.FD, pred.train)

train=cbind(hasil_train$overall[1],hasil_train$byClass[1],hasil_train$byClass[2], aucdata_train)
  colnames(train)=c("accuracy","sensitivity","specificity","AUC")
  rownames(train)="Training"

#confusion matrix & auc data test

hasil_test=confusionMatrix(table(pred.test,datatest$KONDISI.FD))
  aucdata_test=auc(datatest$KONDISI.FD, pred.test)

test=cbind(hasil_test$overall[1],hasil_test$byClass[1],hasil_test$byClass[2], aucdata_test)
  colnames(test)=c("accuracy","sensitivity","specificity","AUC")
  rownames(test)="Testing"

#ROC
  predtrain <- prediction(pred.train,
datatrain$KONDISI.FD)
  perfrtrain <- performance(predtrain, "tpr", "fpr")
  predtest <- prediction(pred.test, datatest$KONDISI.FD)
  perftest <- performance(predtest, "tpr", "fpr")

#output
  cm.train
  acc.train
  cm.test
  acc.test

```

```
print(train)
print(test)
summary(model)
OR
plot(perftrain, col="red", main="ROC Curve Train")
win.graph()
plot(perftest, col="red", main="ROC Curve Test")
```

Lampiran 45. Syntax GEVR

```

rm(list=ls())

datatrain_x = read.csv("D:/Bismilah TA/data/Training
Testing/datatrain0.csv", sep=",", header=TRUE)
datatest_x = read.csv("D:/Bismilah TA/data/Training
Testing/datatest0.csv", sep=",", header=TRUE)
datatrain = datatrain_x[,-1]
datatest = datatest_x[,-1]

library(data.table)
library(caret)
library(pROC)
library(ROCR)
library(bgeva)

x1=datatrain$LDR
x2=datatrain$ROA
x3=datatrain$ROE
x4=datatrain$NIM
x5=datatrain$BOPO
x6=datatrain$AKTIVA.PRODUKTIF.BERMASALAH
x7=datatrain$NPL
x8=datatrain$PPAP.TERHADAP.AKTIVA.PRODUKTIF
x9=datatrain$PEMENUHAN.PPAP
x10=datatrain$CAR
x11=datatrain$ATTM
x12=datatrain$INFLASI
x13=datatrain$PERTUMBUHAN.EKONOMI

y <- as.integer(datatrain$KONDISI.FD)

dataSim <-
data.frame(y,x1,x2,x3,x4,x5,x6,x7,x8,x9,x10,x11,x12,x13)

```

```

out <- bgeva(y ~ x1 + x2 + x3 + x4 + x5 + x6 + x7 + x8 +
x9 + x10 + x11 + x12 + x13 , data=dataSim,
           pr.tol = 1e-5, rmax=500, tau=0.1,
           control=list(tol=1e-5), Hes=FALSE)

```

```

parameter = (out$fit$argument)

```

```

peluang = function (param , covariate, tau){
  n=nrow(covariate)
  tau=tau
  beta=as.matrix(param)
  xgab=as.matrix(cbind(rep(1,n),covariate))
  peluang1 = array(0,n)
  kelas = array(0,n)

  for(i in 1:n){
    mu = (xgab %*% beta)
    peluang1[i] = exp(-1*((1+(tau*mu[i]))^(1/tau)))
    if (peluang1[i] > 0.5)
    {
      kelas[i]=1
    } else{
      kelas[i]=0}
    }
    list(kelas = kelas, peluang1=peluang1)
  }
hasil_train1 = peluang(parameter, datatrain[,-14], 0.1)
hasil_test1 = peluang(parameter, datatest[,-14], 0.1)

pred.train1 = hasil_train1$kelas
pred.train = as.numeric(pred.train1)
pred.test1 = hasil_test1$kelas
pred.test = as.numeric(pred.test1)

```

```
#confusion matrix & auc data train
hasil_train=table(pred.train,datatrain[,14])
aucdata_train=auc(datatrain$KONDISI.FD, pred.train)

#confusion matrix & auc data test
hasil_test=table(pred.test,datatest$KONDISI.FD)
aucdata_test=auc(datatest$KONDISI.FD, pred.test)

#ROC
predtrain <- prediction(pred.train,
datatrain$KONDISI.FD)
perftrain <- performance(predtrain, "tpr", "fpr")
predtest <- prediction(pred.test, datatest$KONDISI.FD)
perftest <- performance(predtest, "tpr", "fpr")

#output
print(hasil_train)
print(hasil_test)
print(aucdata_train)
print(aucdata_test)
summary(out)
plot(perftrain, col="red", main="ROC Curve Train")
win.graph()
plot(perftest, col="red", main="ROC Curve Test")
```

**Lampiran 46. Surat Keterangan Data
SURAT PERNYATAAN**

Saya yang bertanda tangan di bawah ini, mahasiswa Departemen Statistika FMKSD ITS:

Nama : Adriani Widyarani

NRP : 1314 100 106

menyatakan bahwa data yang digunakan dalam Tugas Akhir/Thesis ini merupakan data sekunder yang diambil dari penelitian / buku/ Tugas Akhir/ Thesis/ publikasi lainnya yaitu:

Sumber : Laporan publikasi OJK dan laporan tahunan BI

Keterangan : Diakses pada www.ojk.go.id dan www.bi.go.id

Surat Pernyataan ini dibuat dengan sebenarnya. Apabila terdapat pemalsuan data maka saya siap menerima sanksi sesuai aturan yang berlaku.

Mengetahui
Pembimbing Tugas Akhir

Surabaya, 4 Januari 2018



Dr. rer. poj. Dedy Dwi Prastyo
NIP. 19831204 200812 1 002

Adriani Widyarani
NRP. 1314 100 106

*(coret yang tidak perlu)

BIODATA PENULIS



Penulis bernama lengkap Adriani Widyarani, merupakan anak kedua dari Bapak Indra Darmawan dan Ibu Yohana. Penulis lahir di Nganjuk, 19 Maret 1996. Penulis menempuh pendidikan di SDN Semeru 1 Bogor, SDN Mangkura IV Makassar, SMPN 6 Makassar, SMPN 4 Bogor, dan SMAN 1 Bogor. Penulis diterima di Departemen Statistika FMKSD ITS pada tahun 2014. Selama masa kuliah, penulis aktif pada beberapa organisasi. Pada tahun 2014, penulis menjadi *volunteer* pada kegiatan pengabdian masyarakat HIMASTA-ITS. Kemudian penulis melanjutkan menjadi staff departemen sosial masyarakat HIMASTA-ITS 2015/2016, ketua departemen sosial HIMASTA-ITS 2016/2017, bendahara wilayah Ikatan Himpunan Mahasiswa Statistika Indonesia (IHMSI) 2014/2016, dan bendahara pusat IHMSI 2016/2018. Dalam bidang akademik, penulis pernah meraih juara II dalam Pekan Analisis Statistik, Universitas Mulawarman pada tahun 2017 dan menjadi semifinalis ISCO 2017. Penulis berkesempatan untuk menjadi salah satu penerima beasiswa dari Djarum Foundation angkatan 32 dan mengikuti segala pelatihan dari Djarum Foundation. Penulis juga pernah menjadi delegasi ITS dalam program magang ormawa dengan *Sirindhorn International Institute of Technology* (SIIT), Thailand. Kritik dan saran terkait Tugas Akhir ini dapat diberikan kepada penulis melalui email awidyarani@gmail.com atau telfon pada 08569912985.

