

**ANALISIS PERBANDINGAN KLASIFIKASI *FINANCIAL*  
*DISTRESS* PERUSAHAAN MENGGUNAKAN *SUPPORT VECTOR*  
*MACHINE* DAN *ARTIFICIAL NEURAL NETWORK* PADA  
PERUSAHAAN PERTAMBANGAN 2017-2018**

**TUGAS AKHIR**

**Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh Gelar Sarjana Jurusan  
Statistika**



**Shelly Ila Amalia  
16611091**

**JURUSAN STATISTIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS ISLAM INDONESIA  
YOGYAKARTA  
2020**

## HALAMAN PERSETUJUAN PEMBIMBING

### TUGAS AKHIR

Judul : Analisis Perbandingan Klasifikasi *Financial Distress* Perusahaan Menggunakan *Support Vector Machine* dan *Artificial Neural Network* pada Perusahaan Pertambangan 2017-2018

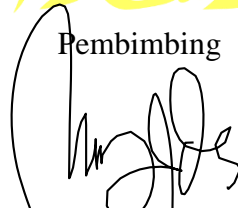
Nama Mahasiswa : Shelly Ila Amalia

Nomor Mahasiswa : 16611091

**TUGAS AKHIR INI TELAH DIPERIKSA DAN DISETUJUI UNTUK  
DIUJIKAN**

Yogyakarta, Desember 2020

Pembimbing



(Mujiati Dwi Kartikasari, S.Si., M.Sc.)

**HALAMAN PENGESAHAN  
TUGAS AKHIR**

**ANALISIS PERBANDINGAN KLASIFIKASI *FINANCIAL DISTRESS*  
PERUSAHAAN MENGGUNAKAN *SUPPORT VECTOR MACHINE* DAN  
*ARTIFICIAL NEURAL NETWORK* PADA PERUSAHAAN PERTAMBANGAN  
2017-2018**

Nama Mahasiswa : Shelly Ila Amalia

NIM : 16611091

**TUGAS AKHIR INI TELAH DI UJIKAN  
PADA TANGGAL 21 DESEMBER 2020**

**Nama Penguji**

**Tanda Tangan**

1. Tuti Purwaningsih, S.Stat., M.Si.
2. Sekti Kartika Dini., S.Si., M.Si.
3. Mujiati Dwi Kartikasari, S.Si., M.Sc.



Mengetahui,

Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



(Prof. Riyanto, S.Pd., M.Si., Ph.D.)

## KATA PENGANTAR

*Bismillahirrahmanirrahim*

*Assalamu'alaikum Wr. Wb.*

Alhamdulillah puji dan syukur kepada Allah SWT yang telah melimpahkan rahmat, nikmat, serta hidayah-Nya sehingga penulis dapat menyelesaikan tugas akhir ini dengan lancar. Shalawat serta salam senantiasa tercurah atas junjungan kita Nabi Muhammad SAW yang telah membawa kita dari zaman kegelapan hingga zaman yang terang-benderang seperti sekarang ini.

Tugas akhir ini dilakukan sebagai salah satu persyaratan yang harus dipenuhi untuk menyelesaikan jenjang strata satu di Jurusan Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Indonesia. Tugas akhir ini disusun berdasarkan data laporan keuangan perusahaan Indonesia yang terdaftar di Bursa Efek Indonesia pada periode 2017-2018.

Dalam penyusunan tugas akhir, penulis mendapatkan banyak semangat, motivasi, masukan, dan bimbingan dari berbagai pihak. Maka penulis ingin mengucapkan terima kasih kepada :

1. Bapak Fathul Wahid, S.T., M.Sc., Ph.D. selaku Rektor Universitas Islam Indonesia yang telah memberikan kesempatan untuk penulis melaksanakan studi di Universitas Islam Indonesia.
2. Bapak Prof. Riyanto, S.Pd., M.Si., Ph.D. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Indonesia.
3. Bapak Dr. Edy Widodo, M.Si. selaku Ketua Program Studi Statistika beserta jajarannya.
4. Ibu Mujiati Dwi Kartikasari, S.Si., M.Sc. selaku dosen pembimbing tugas akhir yang telah sangat sabar dan sangat membantu serta memberikan masukan hingga tugas akhir ini selesai.
5. Seluruh dosen dan karyawan Program Studi Statistika Universitas Islam Indonesia atas bantuan dan dukungan yang diberikan.

6. Bapak Thohir Maksudi, Ibu Kusmatul Fatayati, Mimi Unah, Mimi Was, Nabila Farchani, Harits Majiid, Abira Ulya Rahma, dan Muhammad Rasyid Ridlo selaku keluarga penulis yang selalu memberikan dukungan, motivasi, semangat, serta selalu mendoakan agar penulis diberi kemudahan, kelancaran dalam menyusun tugas akhir ini.
7. Yuffikanamarer yang terdiri dari Sabila Nur Rohmah, Nurfirmanillah Yustitia, Nahara Mahardhika, dan Gemala Adilawaty yang selalu memberikan *support* dan memberikan hiburan kepada penulis.
8. Kom Bongak yang terdiri dari Revata Maggandari, Hidyah Dewi, Mega Luna, dan Zulinda yang menemani dari tahun pertama kuliah sampai tugas akhir ini selesai. Terima kasih karena telah berjuang dan membangun mimpi bersama-sama. Terima kasih karena telah menemani *up and down* penulis selama menjalani masa perkuliahan.
9. Pengurus Inti IKS FMIPA UII Periode 2017-2018, Pengurus INTI LEM FMIPA UII Periode 2018-2019, Inti EC 2019, dan Agen Venus yang telah memberikan warna selama masa perkuliahan.
10. Teman-teman seperjuangan Statistika yang bernama ARTCOS'16 yang sangat membantu penulis dalam menjalankan kuliah.
11. Serta semua pihak yang baik secara langsung ataupun tidak langsung telah membantu penulis menyelesaikan tugas akhir ini.

Demikianlah yang dapat disampaikan, penulis menyadari bahwa dalam tugas akhir ini masih banyak kekurangan dan jauh dari sempurna. Oleh karena itu, penulis sangat mengharapkan banyak kritik dan saran untuk tugas akhir ini.

***Wassalamu'alaikum Wr. Wb.***

Yogyakarta, Desember 2020

Penulis

## DAFTAR ISI

HALAMAN SAMPUL .....	i
HALAMAN PERSETUJUAN PEMBIMBING .....	ii
HALAMAN PENGESAHAN TUGAS AKHIR.....	iii
KATA PENGANTAR .....	iv
DAFTAR ISI.....	vi
DAFTAR TABEL.....	ix
DAFTAR GAMBAR .....	x
DAFTAR LAMPIRAN.....	xi
HALAMAN PERNYATAAN .....	xii
INTISARI.....	xiii
<i>ABSTRACT</i> .....	xiv
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang .....	1
1.2. Perumusan Masalah.....	5
1.3. Batasan Masalah.....	5
1.4. Tujuan Penelitian.....	6
1.5. Manfaat Penelitian.....	6
BAB II TINJAUAN PUSTAKA.....	7
BAB III LANDASAN TEORI.....	10
3.1 <i>Financial Distress</i> .....	10
3.2 Kebangkrutan .....	12
3.3 Laporan Keuangan .....	13
3.3.1 Pengertian Laporan Keuangan .....	13
3.3.2 Tujuan Laporan Keuangan.....	14
3.3.3 Peranan Laporan Keuangan .....	15
3.4 Rasio Keuangan.....	16
3.4.1 Pengertian Rasio Keuangan .....	16

3.4.2	Jenis Rasio Keuangan .....	16
3.5	Statistika Deskriptif .....	19
3.6	Normalisasi Data .....	19
3.7	<i>Balancing Data</i> .....	20
3.8	<i>Artificial Neural Network</i> .....	20
3.8.1	Komponen <i>Artificial Neural Network</i> .....	21
3.8.2	Arsitektur <i>Artificial Neural Network</i> .....	22
3.8.3	Fungsi Aktivasi .....	24
3.8.4	Algoritma Pelatihan <i>Backpropagation</i> .....	25
3.9	<i>Support Vector Machine</i> .....	30
3.9.1	Linear <i>Support Vector Machine</i> .....	31
3.9.2	<i>Soft Margin</i> .....	33
3.9.3	<i>Non-Linear Support Vector Machine</i> .....	34
3.9.4	Kernel .....	35
3.10	<i>Confusion Matrix</i> .....	37
<b>BAB IV</b>	<b>METODOLOGI PENELITIAN</b> .....	<b>38</b>
4.1	Populasi dan Sampel Penelitian .....	38
4.2	Tempat dan Waktu Penelitian .....	38
4.3	Jenis penelitian .....	38
4.4	Data dan Variabel Penelitian .....	39
4.4.1	Variabel Dependen .....	39
4.4.2	<i>Working Capital/Total Asset (X<sub>1</sub>)</i> .....	39
4.4.3	<i>Retained Earning/Total Asset (X<sub>2</sub>)</i> .....	40
4.4.4	<i>Earning Before Interest and Tax/Total Asset (X<sub>3</sub>)</i> .....	40
4.4.5	<i>Market Value Equity/Total Liabilities (X<sub>4</sub>)</i> .....	40
4.5	Metode Analisis .....	41
4.6	Tahapan Penelitian .....	41
<b>BAB V</b>	<b>HASIL DAN PEMBAHASAN</b> .....	<b>44</b>
5.1	Statistika Deskriptif .....	44
5.2	Normalisasi Data .....	48

5.3	<i>Balancing Data</i> .....	49
5.4	Pembagian Data <i>Training</i> dan <i>Testing</i> .....	49
5.5	Metode <i>Support Vector Machine</i> .....	50
5.5.1	RBF Kernel .....	50
5.5.2	Sigmoid Kernel .....	52
5.5.3	Perbandingan RBF Kernel dan Sigmoid Kernel .....	53
5.6	Metode <i>Artificial Neural Network</i> .....	54
5.6.1	Arsitektur Jaringan Saraf Tiruan.....	54
5.6.2	Inisialisasi Bobot.....	55
5.6.3	Pelatihan Model <i>Backpropagation</i> .....	56
5.6.4	Pengujian <i>Backpropagation</i> .....	61
5.7	Perbandingan Metode SVM dan ANN.....	62
BAB VI PENUTUP .....		64
6.1	Kesimpulan.....	64
6.2	Saran.....	64
DAFTAR PUSTAKA .....		65
LAMPIRAN.....		72



## DAFTAR TABEL

Tabel 3. 1 Kernel SVM yang Sering Digunakan .....	37
Tabel 3. 2 <i>Confusion Matrix</i> .....	37
Tabel 5. 1 <i>Balancing Data</i> .....	49
Tabel 5. 2 Pembagian Data <i>Training</i> dan <i>Testing</i> .....	50
Tabel 5. 3 Nilai Akurasi Parameter Terbaik Kernel RBF.....	50
Tabel 5. 4 Parameter Model SVM Kernel RBF.....	51
Tabel 5. 5 <i>Confusion Matrix</i> SVM Kernel RBF.....	51
Tabel 5. 6 Nilai Akurasi Parameter Terbaik Kernel Sigmoid.....	52
Tabel 5. 7 Parameter Model SVM Kernel Sigmoid.....	52
Tabel 5. 8 <i>Confusion Matrix</i> SVM Kernel Sigmoid .....	52
Tabel 5. 9 Rangkuman Akurasi Fungsi Kernel .....	53
Tabel 5. 10 Bobot Awal <i>Input Layer</i> ke <i>Hidden Layer</i> .....	55
Tabel 5. 11 Bobot Awal <i>Hidden Layer</i> ke <i>Output</i> .....	55
Tabel 5. 12 Data <i>Input Training</i> .....	56
Tabel 5. 13 Sinyal <i>Input Layer</i> ke <i>Hidden Layer</i> .....	56
Tabel 5. 14 Sinyal <i>Output</i> di <i>Hidden Layer</i> .....	57
Tabel 5. 15 Sinyal <i>Input</i> dari <i>Hidden Layer</i> ke <i>Output Layer</i> .....	57
Tabel 5. 16 Koreksi Bobot dan Bias di <i>Hidden Layer</i> terhadap <i>Output Layer</i> .....	58
Tabel 5. 17 Faktor Kesalahan di Unit Tersembunyi .....	58
Tabel 5. 18 Faktor Kesalahan di Unit Tersembunyi .....	58
Tabel 5. 19 Koreksi Bobot dan Bias di <i>Input Layer</i> terhadap <i>Hidden Layer</i> .....	59
Tabel 5. 20 Bobot dan Bias Akhir pada <i>Hidden Layer</i> terhadap <i>Output Layer</i> .....	60
Tabel 5. 21 Bobot dan Bias Akhir pada <i>Input Layer</i> terhadap <i>Hidden Layer</i> .....	60
Tabel 5. 22 <i>Confusion Matrix</i> ANN.....	62
Tabel 5. 23 Hasil Perbandingan Metode .....	63

## DAFTAR GAMBAR

Gambar 3. 1 Komponen ANN .....	22
Gambar 3. 2 Arsitektur Lapisan Tunggal.....	23
Gambar 3. 3 Arsitektur Banyak Lapisan.....	23
Gambar 3. 4 Arsitektur Lapisan Kompetitif .....	24
Gambar 3. 5 Fungsi Aktivasi <i>Sigmoid Bipolar</i> .....	25
Gambar 3. 6 Fungsi Aktivasi <i>Sigmoid Biner</i> .....	25
Gambar 3. 7 SVM Linear.....	31
Gambar 3. 8 SVM <i>Non-linear</i> .....	34
Gambar 3. 9 Kernel untuk Memisahkan Data Secara Linear.....	35
Gambar 4. 1 <i>Flowchart</i> .....	42
Gambar 4. 2 <i>Flowchart</i> .....	43
Gambar 5. 1 Perbandingan Perusahaan Financial Distress.....	44
Gambar 5. 2 Histogram Variabel <i>Working Capital/Total Asset</i> .....	45
Gambar 5. 3 Histogram Variabel <i>Retained Earnings/Total Asset</i> .....	46
Gambar 5. 4 Histogram Variabel <i>Earnings before Interest and Tax/Total Asset</i> .....	47
Gambar 5. 5 Histogram Variabel <i>Market Value Equity/Total Liabilities</i> .....	48
Gambar 5. 6 Data Setelah Ditransformasi.....	49
Gambar 5. 9 Rancangan Arsitektur Jaringan .....	54
Gambar 5. 10 Arsitektur Jaringan Saraf Tiruan Klasifikasi Perusahaan <i>Financial Distress</i> .....	61

## DAFTAR LAMPIRAN

Lampiran 1 Data Penelitian.....	72
Lampiran 2 <i>Syntax</i> Program R Metode <i>Support Vector Machine</i> .....	74
Lampiran 3 <i>Syntax</i> Program R Metode <i>Artificial Neural Network</i> .....	76



## HALAMAN PERNYATAAN

Dengan ini saya menyatakan bahwa dalam Tugas Akhir ini tidak terdapat karya yang sebelumnya pernah diajukan untuk memperoleh gelar kesarjanaan disuatu perguruan tinggi dan sepanjang pengetahuan saya juga tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain, kecuali yang diacu di dalam naskah ini dan diterbitkan dalam daftar pustaka.

Yogyakarta, Desember 2020

METERAI  
TEMPEL  
25A C 414 MF 850248118  
6000  
ENAM RIBU RUPIAH

Penulis

**ANALISIS PERBANDINGAN KLASIFIKASI *FINANCIAL*  
*DISTRESS* PERUSAHAAN MENGGUNAKAN *SUPPORT VECTOR*  
*MACHINE* DAN *ARTIFICIAL NEURAL NETWORK* PADA  
PERUSAHAAN PERTAMBANGAN TAHUN 2017-2018**

Oleh : Shelly Ila Amalia

Program Studi Statistika

Fakultas Matematika dan Ilmu Pengetahuan Alam

Universitas Islam Indonesia

**INTISARI**

*Financial distress* adalah tahapan penurunan kondisi keuangan suatu perusahaan sebelum mengalami kebangkrutan. Prediksi *financial distress* bermanfaat bagi perusahaan, investor, dan kreditur. Penelitian ini menggunakan sektor pertambangan di Bursa Efek Indonesia. Variabel yang digunakan adalah rasio keuangan yang mengacu pada penelitian Altman untuk perusahaan selain manufaktur, yaitu *working capital/total asset*, *retained earning/total asset*, *earning before interest and tax/total asset*, dan *market value equity/total liabilities*. Penelitian ini menggunakan metode *Support Vector Machine* dan *Artificial Neural Network*. Kedua metode tersebut akan dibandingkan menggunakan tingkat akurasi sehingga diperoleh metode mana yang lebih baik. Hasil dari metode *Support Vector Machine* menunjukkan tingkat akurasi sebesar 94% menggunakan sigmoid. Untuk metode *Artificial Neural Network* menunjukkan tingkat akurasi sebesar 88%. Jadi, metode *Support Vector Machine* lebih baik daripada metode *Artificial Neural Network* dalam mengklasifikasikan perusahaan sektor pertambangan *financial distress* dan *non financial distress*.

Kata Kunci : *Artificial Neural Network*, *Financial Distress*, *Support Vector Machine*

**COMPARATIVE ANALYSIS OF CLASSIFICATION OF COMPANY  
FINANCIAL DISTRESS USING SUPPORT VECTOR MACHINE  
AND ARTIFICIAL NEURAL NETWORK IN MINING COMPANIES,  
2017-2018**

*By: Shelly Ila Amalia*

*Department of Statistics, Faculty of Mathematics and Science  
Islamic University of Indonesia*

**ABSTRACT**

*Financial distress is a stage of decreasing a company's financial condition before it goes bankrupt. Predictions of financial distress are beneficial for companies, investors and creditors. This research uses mining sector companies on Bursa Efek Indonesia. The variables used are financial ratios which refer to Altman's research for companies other than manufacturing, namely working capital/total assets, retained earnings/total assets, earning before interest and tax/total assets, and market value equity/total liabilities. The method used is Support Vector Machine and Artificial Neural Network. The two methods will be compared using the accuracy level of which method is better. The results of the Support Vector Machine method show an accuracy rate of 94% using sigmoid kernel. The Artificial Neural Network method shows an accuracy rate of 88%. So, the Support Vector Machine method is better than the Artificial Neural Network method in classifying financial distress and non-financial distress mining companies.*

**Keywords:** *Artificial Neural Network, Financial Distress, Support Vector Machine*

# BAB I

## PENDAHULUAN

### 1.1. Latar Belakang

Alat komunikasi yang dapat digunakan oleh pihak internal maupun eksternal dalam mengetahui kondisi perusahaan salah satunya adalah informasi yang terkandung dalam laporan keuangan. Informasi tersebut menyangkut posisi keuangan, kinerja, serta perubahan posisi keuangan suatu perusahaan. Hal tersebut sangat bermanfaat bagi perusahaan dalam pengambilan keputusan ekonomi yang sangat berpengaruh pada status kesulitan keuangan perusahaan. Kesulitan keuangan pada perusahaan yang dapat menyebabkan kebangkrutan disebabkan dalam dua faktor, yaitu faktor eksternal dan internal. Faktor eksternal yang dapat menyebabkan kebangkrutan seperti terjadinya kesulitan bahan baku atau kesulitan sumber daya perusahaan, sehingga perusahaan kehilangan kesempatan dalam melakukan produksi dan menghasilkan profit. Sedangkan faktor internal yang menyebabkan kebangkrutan adalah ketika perusahaan sudah tidak mampu lagi membayar semua utang-utangnya dan memenuhi kewajibannya sehingga perusahaan mulai melakukan pembubaran dan akan mulai berdampak pada pengesahan pailit (Ondang, 2013).

Tahap awal kebangkrutan yang terjadi dalam perusahaan biasanya diawali dengan terjadinya *financial distress*. *Financial distress* didefinisikan sebagai tahap penurunan kondisi keuangan yang terjadi sebelum kebangkrutan ataupun likuidasi (Platt & Platt, 2002). Pihak yang sangat membutuhkan informasi kesehatan laporan keuangan adalah kreditor, investor, pembuat regulasi, auditor, dan manajemen (Kariyoto, 2018). *Financial distress* tidak hanya merugikan pihak perusahaan saja, tetapi juga merugikan pihak lain yang berhubungan dengan perusahaan tersebut (Nindita, 2014). Apabila ditinjau dari kondisi keuangan, ada tiga keadaan yang saling berkaitan yang menyebabkan *financial distress* yaitu faktor ketidakcukupan modal atau kekurangan modal, besarnya beban utang dan bunga, dan menderita kerugian (Afriyeni, 2013).

Semakin awal tanda-tanda *financial distress* diketahui, maka akan semakin baik bagi pihak manajemen. Risiko *financial distress* suatu perusahaan dapat dilihat dan diukur melalui laporan keuangan, dengan melakukan analisis terhadap rasio-rasio laporan keuangan tersebut. Rasio utang yang tinggi akan meningkatkan risiko *financial distress*. Jika sebuah perusahaan mengalami masa-masa sulit dan laba operasi tidak cukup untuk menutupi beban bunga, para pemegang sahamnya harus menutupi kekurangan tersebut dan jika mereka tidak dapat melakukannya, maka akan terjadi kebangkrutan (Brigham & Houston, 2006).

Penelitian terkait *financial distress* diawali oleh Beaver pada tahun 1966, kemudian diteruskan oleh Edward Altman pada tahun 1968 yang menghasilkan model yang dapat diterapkan untuk memprediksi *financial distress*. Hasil penelitian Altman menghasilkan rumus yang disebut *Z-Score*. Rumus ini adalah model rasio yang menggunakan *multiple discriminant analysis* (MDA). Dalam metode MDA diperlukan lebih dari satu rasio keuangan yang berkaitan dengan kebangkrutan perusahaan. Rasio yang digunakan oleh Altman adalah *working capital/total asset*, *retained earning/total asset*, *earning before interest and tax/total asset*, *market value equity/total liabilities*, dan *sales/total asset*. Rumus *Z-Score* yang pertama dihasilkan Altman ini atas berbagai perusahaan manufaktur di Amerika Serikat yang menjual sahamnya di bursa efek. Karena itu, model yang dihasilkan menggunakan lima rasio tersebut lebih cocok digunakan untuk memprediksi keberlangsungan usaha perusahaan-perusahaan manufaktur yang *go public* (Rudianto, 2013). Altman terus melakukan revisi pada penelitiannya untuk mengikuti perkembangan zaman agar dapat digunakan pada setiap perusahaan. Pada penelitian terakhirnya, Altman menghilangkan rasio *sales/total asset* atas dasar ukuran perusahaan terkait dengan aset atau penjualan dapat dihilangkan. Sehingga model yang dihasilkan dapat digunakan pada setiap perusahaan *go public* dan *non-go public*. Munculnya berbagai model prediksi kebangkrutan merupakan antisipasi dan sistem peringatan dini terhadap *financial distress*, karena model tersebut dapat digunakan sebagai sarana



untuk mengidentifikasi bahkan memperbaiki kondisi sebelum dan sampai pada kondisi krisis atau kebangkrutan (Endri, 2009).

Penelitian ini menggunakan sektor pertambangan sebagai objek penelitian. Sektor pertambangan adalah salah satu sektor yang dapat dijadikan penopang dalam pembangunan ekonomi di Indonesia karena menyediakan sumber daya energi yang diperlukan untuk pertumbuhan perekonomian nasional. Sektor pertambangan terbagi menjadi beberapa sub sektor seperti batubara, minyak dan gas bumi, logam dan mineral, dan batu-batuan (Dewi, Handayani, & Nuzula, 2014). Sektor yang sangat menarik para investor salah satunya adalah pertambangan. Adanya pembatasan produksi, khususnya di Izin Usaha Pertambangan daerah sehingga tidak terjadi *over supply* dan kebutuhan konsumsi di Asia yang terus berkembang yang mendorong sektor ini masih sangat diminati oleh para investor (Anggraeni, 2019). Pada tahun 2000an perusahaan pertambangan sempat menjadi salah satu bisnis yang paling menguntungkan, namun dengan berjalannya waktu pada tahun 2014 perusahaan pertambangan mengalami penurunan pendapatan dikarenakan masalah-masalah ekonomi global (Limanto, 2016). Terjadinya perlemahan ekonomi masih terus terjadi hingga tahun 2018, hal ini terjadi dimana ketika pertumbuhan negara maju diperkirakan masih dalam kondisi yang kurang baik. Perusahaan-perusahaan yang ada di sektor pertambangan harus mampu bersaing untuk menghadapi semua kondisi dan keadaan tersebut, karena hal tersebut akan menyebabkan aktivitas bisnis menjadi buruk dan jika perusahaan tidak dapat bertahan akan membuat perubahan kondisi keuangan perusahaan menjadi tidak sehat.

Perubahan kondisi perekonomian mempengaruhi kinerja keuangan, baik perusahaan kecil maupun besar. Prediksi *financial distress* telah menjadi area penelitian kritis yang terbagi ke dalam 2 periode. Periode pertama menggunakan teknik statistika tradisional dan periode kedua menggunakan teknik non-linear (Salehi, Shiri, & Pasikhani, 2016). Metode teknik non-linear yang biasa digunakan adalah *artificial neural network*, *support vector machine*, *decision trees*, *trait recognition*, dan lain-lain. Tidak adanya asumsi linearitas dan normalitas menjadi

kelebihan dari teknik data mining (Alifia & Rikumahu, 2020). Sebagian besar peneliti membandingkan kinerja atau ketepatan prediksi antara salah satu teknik dengan teknik yang lain. Dari berbagai penelitian terkait *financial distress* yang sudah dilakukan, tidak dapat ditarik kesimpulan bahwa terdapat suatu teknik yang secara konsisten lebih baik dibandingkan dengan teknik lainnya dalam memprediksi *financial distress* (Gamayuni, 2009).

Dari beberapa teknik *data mining*, penelitian ini menggunakan metode *Artificial Neural Network* (ANN) dan *Support Vector Machine* (SVM) untuk dibandingkan sehingga diperoleh metode yang lebih baik untuk memprediksi *financial distress* dari beberapa perusahaan. Metode ANN adalah salah satu model prediksi *data mining* yang terkenal dengan keakuratannya dalam prediksi. ANN merupakan model matematis otak manusia yang menyimulasikan interaksi saraf dalam pengolahan data dan pembelajaran dari pengalaman (McLeod, 2002). ANN terdiri dari sejumlah prosesor sangat sederhana dan saling berhubungan yang disebut neuron (Kurniawansyah, 2018). Dengan adanya algoritma ANN maka dapat diprediksi perusahaan mana saja yang mengalami kebangkrutan. Berdasarkan beberapa penelitian yang pernah dilakukan, ANN merupakan salah satu metode yang dapat digunakan untuk memprediksi *financial distress* perusahaan (Salehi, Shiri, & Pasikhani, 2016).

Metode SVM berada dalam satu kelas dengan ANN tetapi dalam banyak implementasi terbukti bahwa SVM memberikan hasil yang lebih baik daripada ANN. Ide dasar dari SVM adalah memetakan data input ke dalam ruang berdimensi tinggi dimana nantinya akan ditemukan fungsi pemisah yang linear. Untuk menemukan fungsi pemisah ini, cara kerja SVM adalah memaksimalkan jarak diantara dua titik terdekat dari dua kelas yang berbeda. Untuk memperkecil waktu komputasi dan meningkatkan akurasi dari model maka diperlukan pencarian nilai optimal dari parameter yang digunakan dalam SVM.

Berdasarkan uraian di atas, dalam penelitian ini, peneliti ingin mengetahui ketepatan metode ANN dan SVM dalam memprediksi kebangkrutan perusahaan

menggunakan rasio keuangan sehingga dapat membantu mengelompokkan perusahaan *financial distress* dan *non financial distress* pada perusahaan pertambangan. Berdasarkan penyesuaian Altman, maka rasio keuangan yang digunakan adalah *working capital/total asset*, *retained earning/total asset*, *earning before interest and tax/total asset*, dan *market value equity/total liabilities*. Ketepatan akurasi dari metode ANN dan SVM akan dibandingkan menggunakan metode evaluasi yaitu *confusion matrix* untuk mengetahui metode apakah yang paling akurat untuk memprediksi perusahaan *financial distress* dan *non financial distress*.

### **1.2. Perumusan Masalah**

Berdasarkan uraian latar belakang di atas, dapat dirumuskan permasalahan dalam penelitian ini sebagai berikut :

- 1) Bagaimanakah gambaran umum rasio keuangan yang digunakan untuk analisis *financial distress* perusahaan sektor pertambangan tahun 2018 di Indonesia?
- 2) Berapa besar ketepatan metode klasifikasi menggunakan metode *Support Vector Machine* dan *Artificial Neural Network* dalam memprediksi perusahaan *financial distress* dan *non financial distress*?
- 3) Manakah metode yang paling akurat untuk memprediksi *financial distress* pada perusahaan sektor pertambangan tahun 2017-2018 di Indonesia?

### **1.3. Batasan Masalah**

Agar pembahasan tidak terlalu luas, maka penelitian ini diberikan batasan permasalahan sebagai berikut:

1. Data yang digunakan adalah data dari rasio keuangan perusahaan sektor pertambangan yang terdaftar di Bursa Efek Indonesia tahun 2018.
2. Variabel yang digunakan adalah *working capital/total asset*, *retained earning/total asset*, *earning before interest and tax/total asset*, dan *market value equity/total liabilities*.
3. Metode yang digunakan adalah *Artificial Neural Network* dan *Support Vector Machine*.

4. Perangkat lunak yang digunakan adalah R-3.6.1 dan *Microsoft Excel* 2010.

#### **1.4. Tujuan Penelitian**

Berdasarkan rumusan masalah di atas, maka penelitian ini memiliki tujuan untuk:

1. Mengetahui gambaran umum rasio keuangan yang digunakan untuk analisis kebangkrutan perusahaan sektor pertambangan tahun 2018 di Indonesia.
2. Mengetahui seberapa tepat metode *Support Vector Machine* dan *Artificial Neural Network* dalam memprediksi perusahaan *financial distress* dan *non financial distress*.
3. Mengetahui manakah metode yang paling akurat untuk memprediksi *financial distress* pada perusahaan sektor pertambangan tahun 2017-2018 di Indonesia.

#### **1.5. Manfaat Penelitian**

Manfaat dalam penelitian ini adalah sebagai berikut:

1. Mendapatkan bahan referensi dan evaluasi dalam memprediksi analisis *financial distress* untuk dijadikan pertimbangan dalam menentukan keputusan perusahaan.
2. Menambah pengetahuan bagi penulis tentang penerapan metode *Artificial Neural Network* dan *Support Vector Machine* dalam memprediksi *financial distress*.
3. Dapat digunakan sebagai referensi untuk penelitian selanjutnya.

## **BAB II**

### **TINJAUAN PUSTAKA**

Pada penelitian ini, penulis menggunakan beberapa rujukan penelitian yang sebelumnya sudah dilakukan. Hal ini ditujukan sebagai dasar atau acuan agar penelitian ini akurat. Penelitian terdahulu berperan sangat penting agar dapat diketahui perbedaan antara penelitian sebelumnya dengan penelitian yang akan dilakukan oleh penulis saat ini. Berikut ini akan dijelaskan beberapa penelitian sebelumnya yang berkaitan dengan penelitian yang akan dilakukan yaitu mengenai prediksi *financial distress* perusahaan menggunakan *support vector machine* dan *artificial neural network* pada perusahaan pertambangan.

Pada penelitian yang dilakukan oleh Chang Lee dan Chang To (2010) yang berjudul *Comparison of Support Vector Machine and Back Propagation Neural Network in Evaluating the Enterprise Financial Distress*. Penelitian ini menggunakan data dari perusahaan basis data di Taiwan sebanyak 20 data *training* dan 25 data *testing*. Variabel yang digunakan sebanyak 15 yang terdiri dari rasio keuangan yaitu *debt ratio*, *stockholder/total assets*, *earning per share*, *return on total assets*, *return on stockholders equity*, *profit margin*, *fixed assets turnover ratio*, *account receivable turnover ratio*, *average collection period*, *inventory turnover ratio*, *average days to sell the inventory*, *current ratio*, *quick ratio*, *asset-liability current ratio*. Pada penelitian ini, menggunakan metode SVM mendapatkan hasil bahwa klasifikasi menggunakan kernel radial dengan gamma 0.25 dan *cost* 1. Akurasi yang didapat dari metode SVM adalah 100% dengan 108 iterasi. Untuk metode ANN mendapatkan hasil akurasi sebesar 95% dengan iterasi sebanyak 258. Hasil yang didapat dari metode *Support Vector Machine* dan *Artificial Neural Network*, akurasi pada metode *Support Vector Machine* lebih baik daripada metode *Artificial Neural Network*.

Menurut Horak, Vrbka, dan Suler (2020) pada penelitiannya yang berjudul *Support Vector Machine Methods and Artificial Neural Networks Used for the Development of Bankruptcy Prediction Models and their Comparison*. Penelitian ini

menggunakan data perusahaan industri yang beroperasi di Republik Ceko yang bersumber dari database *the albertina*. Penelitian ini menggunakan 22 variabel independen dan 1 variabel dependen. Data yang digunakan dibagi dalam 75% data *train* dan 25% data *test*. Dari hasil yang didapat pada SVM, akurasi yang diperoleh lebih dari 99% prediksi yang benar dari perusahaan yang aktif dan hanya di atas 8% dari prediksi perusahaan dalam likuidasi. Pada metode ANN yang digunakan adalah MLP (*multilayer perceptron*). ANN memiliki 22 *neuron*, 12 *neuron* di lapisan tersembunyi dan 2 *neuron* di lapisan keluaran. Akurasi yang didapat pada metode ANN ini sebesar 81%. Hasil yang didapat dari metode *Support Vector Machine* dan *Artificial Neural Network*, akurasi pada metode *Support Vector Machine* lebih baik daripada metode *Artificial Neural Network*.

Pada jurnal penelitian yang dilakukan oleh Matsumaru, Kawanaka, Kaneko, dan Katagiri (2019) yang berjudul *Bankruptcy Prediction for Japanese Corporations using Support Vector Machine, Artificial Neural Network, and Multivariate Discriminant Analysis*. Jurnal ini diterbitkan oleh *international journal of industrial engineering and operations management* tahun 2019. Peneliti menggunakan tiga metode yaitu *multivariate discriminant analysis*, *artificial neural network*, dan *support vector machine*. Dari ketiga metode tersebut akan dicari akurasi terbaik yang menyatakan metode apa yang terbaik dengan menggunakan *confusion matrix*. Penelitian ini juga menganalisis lebih baik menggunakan rasio keuangan yang banyak atau tidak untuk meneliti prediksi kebangkrutan. Variabel yang akan digunakan adalah rasio keuangan yang terdiri dari 23 variabel dan 115 variabel. Data ini dibagi menjadi 85% data *train* dan 15 data *test*. Lalu, akan dilihat lebih baik menggunakan banyak variabel atau tidak. Hasil akurasi pada masing-masing metode yang didapatkan pada 23 variabel, yaitu 99.38% pada metode MDA, 99.66% pada metode ANN, dan 99.99% pada metode SVM. Untuk 115 variabel, akurasi yang didapatkan adalah 99.27% pada metode MDA, 99.65% pada metode ANN, dan 99.91% pada metode SVM. Sehingga dapat disimpulkan bahwa dari ketiga metode tersebut, metode SVM lebih akurat dibandingkan model lainnya dalam memprediksi risiko

kebangkrutan perusahaan. Dalam metode MDA dan ANN, prediksi kebangkrutan hanya dibuat secara akurat untuk beberapa industri. Namun, SVM dapat memprediksi kebangkrutan di perusahaan hampir secara sempurna baik untuk seluruh industri maupun industri individu.

Penelitian juga dilakukan oleh Amalia (2018) yang berjudul Perbandingan Metode *Data Mining* SVM dan NN untuk Klasifikasi Penyakit Ginjal Kronis. Penelitian ini menggunakan data penyakit ginjal kronis yang diperoleh dari *uci repositoy* sebanyak 400 *record* dan terdiri dari 24 atribut dan satu label. Hasil dengan metode *neural network* mendapatkan akurasi sebesar 93.36% dan metode *support vector machine* mendapatkan akurasi sebesar 95.16%. Hasil yang diperoleh termasuk dalam jenis klasifikasi sangat baik. Sehingga dapat disimpulkan bahwa metode *neural network* dan *support vector machine* memiliki kinerja yang baik untuk pengolahan dataset penyakit ginjal kronis. Dan dari hasil penelitian diketahui untuk dataset ginjal kronis bahwa metode *support vector machine* menghasilkan nilai akurasi yang lebih tinggi dari metode *neural network*.

Mengacu pada penelitian sebelumnya yang telah dilakukan terdapat beberapa kesamaan yaitu meneliti menggunakan metode *support vector machine* dan *artificial neural network* untuk mendapatkan metode terbaik dalam klasifikasi. Hal yang membedakan penelitian ini dengan penelitian sebelumnya adalah pada objek penelitian. Penelitian ini menggunakan perusahaan sektor pertambangan di Indonesia pada tahun 2017-2018. Data tersebut merupakan data sekunder yang diperoleh dari *website* Bursa Efek Indonesia.



## **BAB III**

### **LANDASAN TEORI**

#### **3.1 *Financial Distress***

Kesulitan Keuangan atau biasa disebut *Financial distress* merupakan kondisi dimana perusahaan sedang menghadapi kesulitan untuk memenuhi kewajibannya, atau keadaan dimana pendapatan perusahaan tidak dapat menutupi total biaya dan mengalami kerugian (Hery, 2017). *Financial distress* juga didefinisikan sebagai tahapan penurunan kondisi keuangan suatu perusahaan sebelum terjadinya kebangkrutan ataupun likuidasi (Platt & Platt, 2002). Kondisi keuangan dapat ditinjau menggunakan komposisi neraca yaitu perbandingan jumlah aktiva dan kewajiban dimana pada saat aktiva tidak cukup atau lebih kecil daripada jumlah utangnya, modal kerja yang negatif sehingga terjadi ketidakseimbangan antara modal dengan utang-piutang perusahaan. Hal ini berdampak pada kegiatan perusahaan dimana perusahaan tidak mampu membiayai seluruh biaya operasionalnya. Biaya yang harus dipenuhi tersebut meliputi biaya bahan baku, biaya *overhead*, pembayaran kompensasi bagi karyawan, utang yang telah jatuh tempo, dan biaya-biaya lainnya (Nirmalasari, 2018). Jika dari perhitungan tersebut perusahaan terus-menerus merugi dan dari arus kas masuk lebih kecil dari arus kas keluar maka dapat dicurigai perusahaan tersebut mengalami *financial distress*.

Indikator *financial distress* dapat dilihat dari analisis aliran kas, analisis strategi perusahaan, dan laporan keuangan perusahaan (Rizki, 2019). Jika dilihat dari kondisi keuangan terdapat tiga hal yang dapat menyebabkan terjadinya *financial distress* yaitu faktor ketidakcukupan modal atau kekurangan modal, besarnya beban utang dan bunga, dan menderita kerugian (Pratama, 2016). Tiga hal tersebut saling berkaitan, sehingga perusahaan harus mampu menjaga aspek-aspek tersebut agar terhindar dari kondisi *financial distress* yang mengarah kepada kebangkrutan.

Informasi perusahaan sedang mengalami *financial distress* adalah hal yang penting untuk setiap perusahaan. Hal ini menjadi manfaat bagi pihak dalam



perusahaan karena dapat menjadi peringatan, sehingga perusahaan dapat mengambil kebijakan untuk menstabilkan kondisi keuangan perusahaan. Menurut Hanafi dan Abdul (2009), pihak-pihak yang menggunakan informasi *financial distress* meliputi :

- a. Pemberi Pinjaman. Informasi *financial distress* bisa bermanfaat untuk mengambil keputusan siapa yang akan diberi pinjaman.
- b. Investor. Saham atau obligasi yang dikeluarkan perusahaan dapat memperlihatkan kemungkinan terjadinya *financial distress* atau tidaknya perusahaan yang menjual surat berharganya tersebut.
- c. Pemerintah. Untuk beberapa sektor usaha, pemerintah mempunyai tanggung jawab untuk mengawasi jalannya usaha, misalnya sektor perbankan.
- d. Akuntan dan auditor. Informasi *financial distress* akan menjadi perhitungan akuntan atau auditor untuk menilai kemampuan *going concern* suatu perusahaan.
- e. Manajemen. Apabila perusahaan mengalami *financial distress* maka perusahaan akan menanggung biaya keseluruhan, sehingga jika perusahaan mengetahui informasi *financial distress* maka perusahaan akan melakukan suatu pencegahan. (Hanafi & Halim, 2009)

Setiap perusahaan mempunyai perjanjian-perjanjian dalam bentuk kewajiban yang harus dijalankan sesuai jangka waktu yang telah disepakati. Jika kewajiban tersebut tidak dapat dilakukan, maka hal tersebut dapat menjadi tanda-tanda bahwa perusahaan tersebut sedang dalam kondisi *financial distress*. Tanda-tanda perusahaan yang mengalami *financial distress* adalah sebagai berikut:

- a. Terjadi penurunan secara signifikan terhadap penjualan dan pendapatan.
- b. Laba atau arus kas dari operasional mengalami penurunan.
- c. Penurunan total aktiva.
- d. Terjadi penurunan secara signifikan terhadap *close price*.
- e. Kemungkinan gagal yang besar dalam industri atau industri dengan risiko yang tinggi.
- f. Terjadi pemotongan deviden yang besar (Lesmana & Surjanto, 2004)

Perusahaan akan sangat dimudahkan dengan adanya informasi *financial distress*, karena perusahaan dapat memutuskan kebijakan untuk mencegah terjadinya kebangkrutan. Menurut Rodoni dan Ali, berikut adalah hal-hal yang dapat mengatasi *financial distress* :

- a. Menjual aset-aset utama, melakukan merger dengan perusahaan lain, menurunkan pengeluaran, biaya penelitian dan pengembangan.
- b. Menerbitkan sekuritas baru, mengadakan negosiasi dengan bank dan kreditor. (Rodoni & Muslih, 2008)

### **3.2 Kebangkrutan**

Kebangkrutan adalah kesulitan yang sangat parah sehingga perusahaan tidak mampu untuk menjalankan operasi perusahaan dengan baik. Analisis kesulitan keuangan akan sangat membantu pembuat keputusan untuk menentukan sikap terhadap perusahaan yang mengalami kesulitan keuangan (Gamayuni, 2009).

Sebelum mengalami kebangkrutan, perusahaan akan mengalami tahapan kebangkrutan. Tahapan kebangkrutan merupakan gejala awal perusahaan hingga dinyatakan mengalami kebangkrutan. Tahapan dari kebangkrutan tersebut diantaranya sebagai berikut:

- a. *Latency*. Pada tahap *latency*, *return of asset* (ROA) akan mengalami penurunan.
- b. *Shortage of cash*. Dalam tahap kekurangan kas, perusahaan tidak memiliki cukup sumber daya kas untuk memenuhi kewajiban saat ini, meskipun masih mungkin memiliki tingkat profitabilitas yang kuat.
- c. *Financial distress*. Kesulitan keuangan dapat dianggap sebagai keadaan darurat keuangan, dimana kondisi ini mendekati kebangkrutan.
- d. *Bankruptcy*. Jika perusahaan tidak dapat lagi menyembuhkan gejala kesulitan keuangan (*financial distress*), maka perusahaan akan bangkrut (Kordestani, Biglari, & Bakhtiari, 2011).

Menurut Ross dalam bukunya, jenis kebangkrutan sebagai kegagalan bisa didefinisikan sebagai berikut:

a. Kegagalan bisnis (*business failure*)

Situasi dimana bisnis berakhir dengan kerugian kredit dan bahkan semua modal perusahaan bisa berkurang.

b. Kebangkrutan menurut hukum (*legal bankruptcy*)

Keadaan dimana perusahaan atau kreditor membawa petisi ke pengadilan federal mengenai kebangkrutan. Kebangkrutan di sini adalah dimana perusahaan sedang dalam proses hukum untuk melikuidasi dan mereorganisasi bisnis.

c. Insolvensi teknis (*technical insolvency*)

Suatu keadaan dimana perusahaan tidak dapat memenuhi kewajibannya pada saat jatuh tempo.

d. Insolvensi akuntansi (*accounting insolvency*)

Dimana perusahaan memiliki pendapatan yang negatif dan total kewajibannya lebih besar dibandingkan aktivasnya (Ross, Westerfield, & Jordan, 2006).

### **3.3 Laporan Keuangan**

#### **3.3.1 Pengertian Laporan Keuangan**

Laporan keuangan adalah catatan informasi keuangan suatu perusahaan pada suatu periode akuntansi yang dapat digunakan untuk menggambarkan kinerja perusahaan. Kondisi keuangan suatu perusahaan akan dapat diketahui dari laporan keuangan perusahaan yang bersangkutan, terdiri dari neraca, laporan laba rugi serta laporan keuangan lainnya (Riswan & Kesuma, 2014). Menurut Pernyataan Standar Akuntansi Keuangan (PSAK) No 1, laporan keuangan adalah suatu penyajian terstruktur dari posisi keuangan dan kinerja keuangan suatu entitas. Laporan keuangan juga mencerminkan kemajuan atau kemunduran suatu perusahaan dalam periodik (Yuanita, 2010). Informasi yang didapatkan dari laporan keuangan dapat digunakan sebagai pertimbangan dalam pengambilan keputusan, baik oleh manajemen perusahaan maupun pihak eksternal perusahaan. Laporan keuangan

bersifat historis serta menyeluruh dan terdiri dari data-data yang merupakan hasil dari suatu kombinasi antara: fakta yang telah dicatat (*recorder fact*), prinsip dan kebiasaan-kebiasaan dalam akuntansi (*accounting conversion and postulate*), dan pendapat pribadi (*personal judgement*) (Ramadhan & Syarfan, 2016).

### **3.3.2 Tujuan Laporan Keuangan**

Tujuan laporan keuangan adalah menyediakan informasi yang menyangkut posisi keuangan, kinerja suatu perusahaan yang bermanfaat bagi sejumlah besar pemakai dalam mengambil keputusan, menggambarkan pengaruh keuangan dari kejadian masa lalu, dan menunjukkan apa yang telah dilakukan manajemen atau pertanggungjawaban manajemen atas sumber daya yang dipercayakan kepadanya (Ramadhan & Syarfan, 2016).

Kasmir (2009), menjelaskan beberapa tujuan pembuatan atau penyusunan laporan keuangan selain yang sudah disebutkan di atas. Salah satunya adalah sebagai berikut:

- a. Memberikan informasi tentang jenis dan jumlah aktiva (harta) yang dimiliki perusahaan pada saat ini.
- b. Memberikan informasi tentang jenis dan jumlah kewajiban dan modal yang dimiliki perusahaan saat ini.
- c. Memberikan informasi tentang jenis dan jumlah pendapatan yang diperoleh pada suatu periode tertentu.
- d. Memberikan informasi tentang jumlah biaya dan jenis biaya yang dikeluarkan perusahaan dalam suatu periode tertentu.
- e. Memberikan informasi tentang perubahan yang terjadi terhadap aktiva, pasiva, dan modal perusahaan.
- f. Memberikan informasi tentang kinerja manajemen perusahaan dalam suatu periode.
- g. Memberikan informasi tentang catatan atas laporan keuangan.

Dengan tercapainya tujuan dari laporan keuangan akan memudahkan perusahaan dalam proses pengambilan keputusan. Informasi tentang kondisi

keuangan perusahaan tersebut dapat membantu sebuah perusahaan sebagai bahan evaluasi serta juga perbandingan dampak keuangan yang terjadi akibat dari adanya keputusan ekonomi.

### **3.3.3 Peranan Laporan Keuangan**

Laporan keuangan disusun untuk menyediakan informasi yang relevan mengenai posisi keuangan dan seluruh transaksi yang dilakukan oleh suatu entitas pelaporan selama satu periode pelaporan. Laporan keuangan terutama digunakan untuk membandingkan realisasi pendapatan, belanja, transfer, dan pembiayaan dengan anggaran yang telah ditetapkan, menilai kondisi keuangan, mengevaluasi efektivitas dan efisiensi suatu entitas pelaporan, dan membantu menentukan ketaatannya terhadap peraturan perundang-undangan (Goenawan, Sastranegara, & Rizal, 2012).

Dari masing-masing entitas pelaporan mempunyai kewajiban untuk melaporkan upaya-upaya yang telah dilakukan serta hasil yang dicapai dalam pelaksanaan kegiatan secara sistematis dan terstruktur pada suatu periode pelaporan untuk beberapa kepentingan, yaitu sebagai berikut.

a. Akuntabilitas

Mempertanggungjawabkan pengelolaan sumber daya serta pelaksanaan kebijakan yang dipercayakan kepada entitas pelaporan dalam mencapai tujuan yang telah ditetapkan secara periodik.

b. Manajemen

Membantu para pengguna untuk mengevaluasi pelaksanaan kegiatan suatu entitas pelaporan dalam periode pelaporan sehingga memudahkan fungsi perencanaan, pengelolaan dan pengendalian atas seluruh aset, kewajiban, dan ekuitas dana pemerintah untuk kepentingan masyarakat.

c. Transparasi

Memberikan informasi keuangan yang terbuka dan jujur kepada masyarakat berdasarkan pertimbangan bahwa masyarakat memiliki hak untuk mengetahui secara terbuka dan menyeluruh atas pertanggungjawaban pemerintah dalam

pengelolaan sumber daya yang dipercayakan kepadanya dan ketaatannya pada peraturan perundang-undangan.

d. Keseimbangan Antargenerasi (*intergenerational equity*)

Membantu para pengguna dalam mengetahui kecukupan penerimaan pemerintah pada periode pelaporan untuk membiayai seluruh pengeluaran yang dialokasikan dan apakah generasi yang akan datang diasumsikan akan ikut menanggung beban pengeluaran tersebut.

### **3.4 Rasio Keuangan**

#### **3.4.1 Pengertian Rasio Keuangan**

Rasio keuangan adalah suatu kajian yang melihat perbandingan antara jumlah yang terdapat pada laporan keuangan dengan menggunakan formula-formula yang dianggap *representative* untuk diterapkan (Simanjuntak & Wiwin, 2017). Rasio keuangan juga merupakan suatu perhitungan rasio dengan menggunakan laporan keuangan yang berfungsi sebagai alat ukur dalam menilai kondisi keuangan dan kinerja perusahaan (Hery, 2017). Jadi, rasio keuangan menggunakan angka-angka yang terdapat di dalam laporan keuangan yang mempunyai hubungan yang relevan untuk dibandingkan.

#### **3.4.2 Jenis Rasio Keuangan**

Hasil dari rasio keuangan dapat digunakan untuk menilai perusahaan dalam suatu periode, targetnya sesuai dengan yang direncanakan atau tidak. Jenis rasio keuangan yang digunakan dalam setiap perusahaan berbeda-beda. Penggunaan rasio tergantung dari kebutuhan perusahaan, jadi tidak semua rasio digunakan. Dalam metode Altman *Z-Score* dijelaskan bahwa, penelitiannya menemukan lima rasio yang dapat dikombinasikan untuk melihat perusahaan yang mengalami *financial distress* dan tidak mengalami *financial distress*. Altman melakukan beberapa penelitian dengan objek perusahaan yang berbeda kondisi. Altman melakukan beberapa penelitian dengan objek perusahaan yang berbeda kondisinya. Karena itu, Altman menghasilkan beberapa rumus yang berbeda untuk digunakan pada beberapa perusahaan dengan kondisi yang berbeda. Altman pertama kali melakukan penelitian

atas berbagai perusahaan manufaktur di Amerika Serikat, dan model yang pertama kali dihasilkan lebih cocok digunakan untuk memprediksi keberlangsungan perusahaan manufaktur (Rudianto, 2013).

Jenis rasio yang biasa digunakan adalah *working capital/total assets*, *retained earnings/total assets*, *earning before interest and taxes/total assets*, dan *sales/total asset*. Seiring dengan berjalannya waktu dan penyesuaian terhadap berbagai jenis perusahaan, Altman kemudian merevisi rumus atau modelnya agar dapat diterapkan pada semua perusahaan seperti manufaktur dan non manufaktur. Altman mengeliminasi variabel *sales/total asset* karena rasio ini sangat bervariasi pada industri dengan ukuran aset yang berbeda-beda (Ramadhani & Lukviarman, 2009).

Berikut adalah jenis-jenis rasio keuangan yang sering digunakan perusahaan:

a. Rasio likuiditas

Rasio likuiditas adalah kemampuan suatu perusahaan memenuhi kewajiban jangka pendeknya secara tepat waktu atau pada saat jatuh tempo (Aprylia, 2016). Rasio ini dapat memberikan peringatan kepada pemilik perusahaan tentang masalah arus kas yang akan muncul. Perusahaan dengan likuiditas yang kokoh tidak hanya akan mampu membayar tagihan tepat waktu, tetapi juga mempunyai cukup modal untuk memanfaatkan peluang usaha yang muncul (Rizki, 2019). Jenis-jenis rasio likuiditas adalah:

- 1) Rasio lancar
- 2) Rasio cepat
- 3) Rasio modal kerja
- 4) Rasio likuiditas arus kas

Hasil rasio tersebut dapat negatif apabila aktiva lancar lebih kecil dari kewajiban lancar (Agustina & Rahmawati, 2010). Semakin tinggi rasio likuiditas maka semakin baik kondisi keuangan perusahaan, artinya semakin kecil kemungkinan perusahaan akan mengalami *financial distress*. Namun, rasio likuiditas yang terlalu tinggi menunjukkan bahwa modal kerja perusahaan tidak produktif

mengakibatkan munculnya biaya-biaya yang akan mengurangi laba perusahaan (Pratama, 2016).

b. Rasio profitabilitas

Rasio profitabilitas adalah rasio yang menunjukkan seberapa baik perusahaan dalam mengelola asetnya, khususnya untuk menghasilkan keuntungan setelah dikurangi biaya. Rasio ini juga memberikan informasi tentang laba atau hasil akhir (Rizki, 2019).

Profitabilitas dapat menjadi tolak ukur untuk menilai keberhasilan suatu perusahaan dalam menggunakan modal kerja secara efektif dan efisien. Bagi perusahaan pada umumnya masalah profitabilitas sangat penting daripada laba, karena laba yang besar dapat memastikan bahwa perusahaan tersebut telah bekerja dengan efisien. Dengan demikian, yang harus diperhatikan oleh perusahaan adalah tidak hanya bagaimana usaha untuk memperbesar laba, namun yang lebih penting adalah bagaimana meningkatkan profitabilitas (Sanjaya & Rizky, 2018). Semakin baik rasio profitabilitas maka semakin baik menggambarkan kemampuan tingginya perolehan keuntungan perusahaan.

c. Rasio solvabilitas

Rasio solvabilitas adalah rasio yang digunakan untuk mengukur sejauh mana aktiva perusahaan dibiayai dengan utang. Artinya, berapa besar beban utang yang ditanggung oleh perusahaan dibandingkan dengan aktivanya (Aprylia, 2016). Secara umum, rasio solvabilitas digunakan untuk mengukur kemampuan perusahaan untuk membayar seluruh kewajibannya, baik jangka pendek maupun jangka panjang apabila perusahaan dibubarkan (dilikuidasi) (Shintia, 2017). Tujuan dari rasio solvabilitas adalah untuk mengetahui posisi perusahaan terhadap kewajiban kepada pihak lainnya seperti kreditor, untuk menilai kemampuan dalam memenuhi kewajiban yang bersifat tetap (seperti angsuran pinjaman termasuk bunga), untuk menilai keseimbangan antara nilai aktiva khususnya aktiva tetap dengan modal.

Jika dalam hasil perhitungan, perusahaan ternyata memiliki rasio solvabilitas yang tinggi, hal ini akan berdampak timbulnya resiko kerugian lebih besar, tetapi juga



ada kesempatan mendapat laba lebih besar. Sebaliknya, apabila perusahaan memiliki rasio solvabilitas lebih rendah tentu mempunyai resiko kerugian lebih kecil pula, terutama pada saat perekonomian menurun. Dampak ini juga mengakibatkan rendahnya tingkat hasil pengembalian (*return*) pada saat perekonomian tinggi (Rudianto, 2013).

### **3.5 Statistika Deskriptif**

Statistika deskriptif adalah teknik statistika yang digunakan untuk menganalisis data dengan cara mendeskripsikan atau menggambarkan data yang telah terkumpul sebagaimana adanya tanpa bermaksud membuat kesimpulan yang berlaku untuk umum atau generalisasi. Analisis ini hanya berupa akumulasi data dasar dalam bentuk deskripsi dalam arti tidak mencari atau menerangkan saling hubungan, menguji hipotesis, membuat ramalan, atau melakukan penarikan kesimpulan (Marhamah, Maiyastri, & Asdi, 2011).

Menurut Husaini dan Purnomo, statistika deskriptif dalam arti sempit, ialah susunan angka yang memberikan gambaran tentang data yang disajikan dalam bentuk-bentuk tabel, diagram, histogram, poligon, frekuensi, *ozaiiv (ogive)*, ukuran penempatan (median, kuartil, desil, dan persentil), ukuran gejala pusat (rata-rata hitung, rata-rata ukur, rata-rata harmonik, dan modus), simpangan baku, angka baku, kurval normal, korelasi, dan regresi linier (Usman & Akbar, Pengantar Statistika, 2003).

Statistika deskriptif adalah bagian dari statistik yang mempelajari cara pengumpulan data dan penyajian data sehingga mudah dipahami. Statistika deskriptif hanya berhubungan dengan hal menguraikan atau memberikan keterangan-keterangan mengenai suatu data atau keadaan. Maka statistika deskriptif berfungsi untuk menerangkan keadaan, gejala, atau persoalan (Nasution, 2017).

### **3.6 Normalisasi Data**

Normalisasi data adalah mengubah data ke dalam bentuk yang paling tepat atau cocok untuk proses *data mining*. Normalisasi dilakukan untuk menskalakan atribut numerik dalam *range* yang lebih kecil seperti ke -1 sampai 1 atau 0 sampai 1

(Chamidah, Wiharto, & Salamah, 2012). Normalisasi yang digunakan adalah *min-max normalization*. Rumus *min-max normalization* sebagai berikut:

$$V' = \frac{V - \text{Min}_A}{\text{Max}_A - \text{Min}_A} (\text{New}_{\text{max}_A} - \text{New}_{\text{min}_A}) + \text{New}_{\text{min}_A} \quad (3.1)$$

Keterangan:

$V'$  = Nilai yang dicari

$V$  = Nilai pada variabel A

$\text{Min}_A$  = Nilai minimal variabel A

$\text{Max}_A$  = Nilai maksimal variabel A

$\text{New}_{\text{max}_A}$  = Rentang nilai maksimal pada variabel A

$\text{New}_{\text{min}_A}$  = Rentang nilai minimal pada variabel A

### 3.7 *Balancing Data*

*Balancing* data adalah merubah data yang tidak seimbang (*imbalance* data) menjadi data yang seimbang (*balance*). Suatu kondisi ketidakseimbangan dalam jumlah data *training* antara dua kelas yang berbeda, salah satu kelasnya mempresentasikan jumlah data yang sangat besar (kelas mayoritas), sedangkan kelas lainnya mempresentasikan jumlah data yang sangat kecil (kelas minoritas) (Yahya, 2018). Salah satu solusi untuk *imbalance* data adalah menggunakan SMOTE (*Synthetic Minority Oversampling Technique*), yaitu taktik *sampling* yang mampu meningkatkan akurasi dari pengklasifikasi untuk kelas minor (Triyanto & Kusumaningrum, 2017).

SMOTE memiliki beberapa metode yaitu *oversampling* dan *undersampling*. *Oversampling* adalah metode pembangkitan data minoritas sebanyak data mayoritas. Sedangkan *undersampling* adalah metode untuk mengambil beberapa data mayoritas sehingga jumlah data mayoritas sama besar jumlahnya dengan jumlah data minoritas.

### 3.8 *Artificial Neural Network*

*Artificial neural network* (ANN) merupakan suatu sistem analisis yang proses kerjanya diilhami dari aktivitas jaringan saraf pada manusia. Jaringan ini terdiri dari


sekumpulan *neuron* atau unit yang saling berinteraksi. *Neuron* adalah satuan unit pemroses terkecil pada otak. Pada saraf manusia, proses alami mengatur bagaimana sinyal *input* pada *dendrite* diproses dan kemudian diterjemahkan dalam aktivitas *axon*. Fungsi *dendrite* adalah sebagai penyamapi sinyal dari *neuron* tersebut ke *neuron* yang terhubung dengannya. Sedangkan pada *neuron* buatan, proses *learning* mengatur *input-input* yang digunakan untuk pemetaan *output* (Effendi, 2013). Proses *learning* terjadi pada saat pengaturan pembobotan dan bias. Metode yang paling umum digunakan dalam proses *learning* adalah *backpropagation*. Dalam metode ini, pembobotan diatur untuk meminimalisasi nilai kuadrat beda antara *output* model dan *output* taksiran atau secara umum disebut sebagai nilai kuadrat galat atau *sum of square error*. Istilah buatan digunakan karena jaringan saraf ini diimplementasikan dengan menggunakan program komputer yang mampu menyelesaikan sejumlah proses perhitungan selama proses pembelajaran (Kusumadewi, 2003).

Pembuatan struktur ANN diilhami oleh struktur jaringan biologi, khususnya jaringan otak manusia. ANN mempresentasikan buatan otak manusia yang selalu melakukan proses pembelajaran pada otak manusia tersebut. Sistem pemrosesan informasi yang memiliki karakteristik serupa dengan jaringan saraf biologis, ciri-cirinya adalah sebagai berikut:

1. Pola hubungan antara elemen-elemen sederhana yaitu *neuron*.
2. Algoritma pembelajaran yang berfungsi untuk penggunaan penemuan bobot-bobot jaringan.
3. Fungsi aktivasinya (Amalina, 2016).

### **3.8.1 Komponen *Artificial Neural Network***

Setiap *neuron* dapat memiliki beberapa masukan dan mempunyai satu keluaran. Jalur masukan pada suatu *neuron* bisa berisi data mentah atau data hasil olahan dari *neuron* sebelumnya. Sedangkan hasil keluaran suatu *neuron* dapat berupa hasil akhir atau berupa bahan masukan bagi *neuron* berikutnya.



**Gambar 3. 1** Komponen ANN

Menurut (Hermawan, 2006), ANN mempunyai tiga lapisan sebagai berikut:


1. *Input layer* berfungsi sebagai penghubung jaringan ke dunia luar (sumber data). *Neuron-neuron* ini tidak melakukan apapun pada data, hanya meneruskan data ini ke lapisan berikutnya.
2. *Hidden layer* adalah suatu jaringan yang memiliki lebih dari satu *hidden layer* atau bahkan bisa tidak punya sama sekali. Lapisan ini tersembunyi namun semua proses pada fase pelatihan dan fase pengenalan dijalankan di lapisan ini. *Hidden layer* merupakan lapisan yang menghubungkan antara *input layer* dan *output layer*.
3. *Output layer* menghasilkan nilai keluaran dari hasil perhitungan keseluruhan.

### 3.8.2 Arsitektur *Artificial Neural Network*

Dalam ANN, *neuron* dikelompokkan dalam lapisan-lapisan. Arsitektur dari ANN dibagi menjadi 3 macam, yaitu:

1. Jaringan syaraf dengan lapisan tunggal (*single layer network*), dimana lapisan tunggal ini terdiri dari 1 *layer input*, 1 *layer output*, dan 1 lapisan bobot koneksi. Setiap *neuron* yang terdapat di dalam lapisan *input* selalu

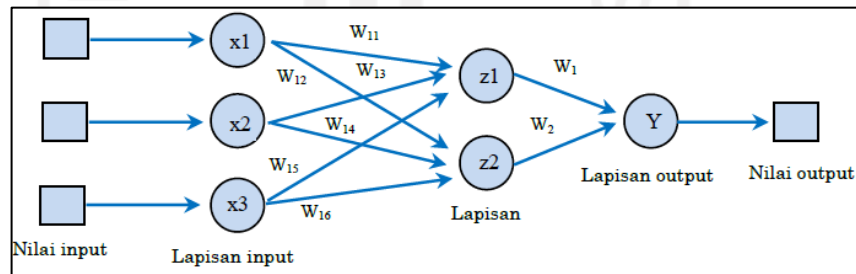
terhubung dengan setiap *neuron* yang terdapat pada lapisan *output*. Jaringan mengalir searah dari *input layer* sampai *output layer* tanpa harus melalui lapisan tersembunyi.



**Gambar 3. 2** Arsitektur Lapisan Tunggal

Sumber : (Lesnussa, Latuconsina, & Persulesy, 2015)


- Jaringan banyak lapisan (*multilayer network*), yang memiliki ciri khas yaitu terdapat jenis lapisan *input*, lapisan *output*, dan lapisan tersembunyi. Jaringan dengan banyak lapisan ini dapat menyelesaikan permasalahan yang lebih kompleks dibandingkan jaringan dengan lapisan tunggal, walaupun proses pelatihan sering membutuhkan waktu yang cenderung lama.



**Gambar 3. 3** Arsitektur Banyak Lapisan

Sumber : (Lesnussa, Latuconsina, & Persulesy, 2015)

- Jaringan lapisan kompetitif (*competitive layer*), dimana sekumpulan *neuron* bersaing untuk mendapatkan hak menjadi aktif. Jaringan ini disebut dengan *feedback loop* karena *output*-nya ada yang memberikan informasi terhadap tiap *input*-nya (Lesnussa, Latuconsina, & Persulesy, 2015)



**Gambar 3. 4** Arsitektur Lapisan Kompetitif

Sumber : (Lesnussa, Latuconsina, & Persulesy, 2015)


### 3.8.3 Fungsi Aktivasi

Fungsi aktivasi dalam ANN berperan sebagai sinyal untuk menentukan keluaran ke beberapa *neuron* lainnya. Fungsi aktivasi ini memiliki peranan sangat penting karena penggunaannya tergantung dengan kebutuhan dan target yang diinginkan serta fungsi aktivasi ini yang akan menentukan besarnya bobot (Puspitaningrum, 2006). Fungsi aktivasi digunakan untuk mengaktifkan setiap *neuron* yang dipakai pada jaringan tersebut. Beberapa fungsi aktivasi yang sering dipakai adalah sebagai berikut:

1. Fungsi *Sigmoid Bipolar*

Fungsi *sigmoid bipolar* adalah fungsi logistik yang memiliki *range output* dari -1 sampai 1. Fungsi ini erat kaitannya dengan fungsi *tangent hyperbolic*, yang sering juga digunakan sebagai fungsi aktivasi ketika *range output* yang diinginkan bernilai -1 sampai dengan 1 (Amalina, 2016). Fungsi *sigmoid bipolar* dirumuskan sebagai:

$$f(x) = \frac{1-e^{-x}}{1+e^{-x}} \quad (3.2)$$




**Gambar 3. 5** Fungsi Aktivasi *Sigmoid Bipolar*

Sumber : (Lesnussa, Sinay, & Idah, 2017)

2. Fungsi *Sigmoid Biner*

Fungsi *sigmoid biner* memiliki kisaran antara 0 sampai 1 sehingga baik digunakan pada jaringan yang memiliki nilai keluaran kisaran antara 0 sampai 1. Fungsi *sigmoid biner* sering digunakan dan sangat baik diterapkan pada *neural network* ketika algoritma pembelajarannya menggunakan metode *backpropagation* (Amalina, 2016). Fungsi *sigmoid biner* dirumuskan sebagai:

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.3)$$



**Gambar 3. 6** Fungsi Aktivasi *Sigmoid Biner*

Sumber : (Lesnussa, Sinay, & Idah, 2017)

**3.8.4 Algoritma Pelatihan *Backpropagation***

Dalam proses pelatihan *backpropagation*, Fauzet (dalam Supriyadi, 2018) menyebutkan terdapat beberapa tahapan, yaitu:

Langkah 0 : Inisialisasi bobot dengan bilangan acak kecil (secara acak).

Langkah 1 : Jika kondisi penghentian belum terpenuhi, kerjakan langkah 2-9.

Langkah 2 Pada setiap pasangan data pelatihan, lakukan langkah 3-8.

### **Fase 1 Feedforward**

Langkah 3 : Tiap unit *input* ( $X_i, i = 1, 2, 3, \dots, n$ ) menerima sinyal  $x_i$  dan meneruskan sinyal tersebut ke semua unit pada lapisan yang ada di atasnya (lapisan tersembunyi/*hidden layer*)

Langkah 4 : Masing-masing unit *hidden layer* dikalikan dengan faktor penimbang dan dijumlahkan serta ditambah dengan biasnya. Seperti persamaan berikut:

$$Z_{in_j} = V_{0j} + \sum_{i=1}^n X_i V_{ij} \quad (3.4)$$

Keterangan:

$Z_{in_j}$  = Keluaran untuk unit  $Z_j$

$V_{0j}$  = Nilai penimbang sambungan pada bias untuk unit  $Z_j$

$X_i$  = Nilai aktivasi dari unit  $X_i$

$V_{ij}$  = Nilai penimbang sambungan dari unit  $X_i$  ke unit  $Z_j$

gunakan fungsi aktivasi untuk menghitung sinyal *output*, seperti persamaan berikut:

$$Z_j = f(Z_{in_j}) \quad (3.5)$$

Keterangan:

$Z_j$  = Nilai aktivasi dari unit  $Z_j$

$Z_{in_j}$  = Keluaran untuk unit  $Z_j$

bila yang digunakan adalah fungsi *sigmoid* maka bentuk fungsi tersebut adalah sebagai berikut:

$$Z_j = \frac{1}{1 + \exp(-Z_{in_j})} \quad (3.6)$$

Keterangan:

$Z_j$  = Nilai aktivasi dari unit  $Z_j$

$Z_{in_j}$  = Keluaran untuk unit  $Z_j$



kemudian mengirim sinyal tersebut ke semua unit pada *output layer*.

Langkah 5 Tiap-tiap unit di *output layer* ( $Y_k, k = 1, 2, 3, \dots, m$ ) menjumlahkan sinyal-sinyal masuk yang berbobot menggunakan persamaan berikut:

$$Y\_in_k = W_{0k} + \sum_{j=1}^p Z_j W_{kj} \quad (3.7)$$

Keterangan:

$Y\_in_k$  = Total sinyal masuk pada keluaran unit ke- $k$

$W_{0k}$  = Nilai penimbang sambungan pada bias untuk unit  $Y_k$

$Z_j$  = Unit ke- $j$  pada lapisan tersembunyi

$W_{kj}$  = Nilai penimbang sambungan dari  $Y_k$  ke unit  $Z_j$

Gunakan fungsi aktivasi untuk menghitung sinyal *output*, seperti pada persamaan berikut:

$$Y_k = f(Y\_in_k) \quad (3.8)$$

$Y_k$  = Keluaran pada unit ke- $k$

$Y\_in_k$  = Total sinyal masuk pada keluaran unit ke- $k$

## **Fase 2 Backpropagation**

Langkah 6 : Tiap unit di *output layer* ( $Y_k, k = 1, 2, 3, \dots, m$ ) menerima pola target berkaitan dengan pola pelatihan masuknya. Hitung galat informasi menggunakan persamaan berikut ini:

$$\delta_k = (t_k - Y_k) Y_k (1 - Y_k) \quad (3.9)$$

Keterangan:

$\delta_k$  = Faktor pengaturan nilai penimbang sambungan pada lapisan keluaran

$t_k$  = Target yang harus dicapai

$Y_k$  = Keluaran pada unit ke- $k$

Kemudian hitung koreksi bobot (digunakan untuk memperbaiki  $W_{jk}$ ) persamaan yang digunakan sebagai berikut:

$$\Delta W_{kj} = \alpha \delta_k Z_j \quad (3.10)$$

Keterangan:

$\Delta W_{kj}$  = Selisih antara  $W_{kj}(t)$  dengan  $W_{kj}(t + 1)$

$\alpha$  = Konstanta laju pelatihan (*learning rate*)

$\delta_k$  = Faktor pengaturan nilai penimbang sambungan pada lapisan keluaran

$Z_j$  = Unit ke- $j$  pada lapisan tersembunyi

Hitung juga nilai koreksi bias (digunakan untuk memperbaiki  $W_{0k}$ ) dengan menggunakan persamaan berikut ini:

$$\Delta W_{0k} = \alpha \delta_k \quad (3.11)$$

Keterangan:

$\Delta W_{0k}$  = Selisih antara  $W_{0k}(t)$  dengan  $W_{0k}(t + 1)$

$\alpha$  = Konstanta laju pelatihan (*learning rate*)

$\delta_k$  = Faktor pengaturan nilai penimbang sambungan pada lapisan keluaran

Faktor  $\delta_k$  kemudian diteruskan ke lapisan yang berada di langkah 7.

Langkah 7 : Tiap unit tersembunyi  $Z_j$  ( $j ; 1, \dots, p$ ) menerima *input* delta dari langkah 6. Kemudian hitung faktor  $\delta$  di setiap unit tersembunyi berdasarkan kesalahan tiap unit tersembunyi menggunakan persamaan berikut:

$$\delta_{in_j} = \sum_{k=1}^m \delta_k W_{jk} \quad (3.12)$$

Keterangan:

$\delta_{in_j}$  = Jumlah kesalahan dari unit tersembunyi

$\delta_k$  = Faktor pengaturan nilai penimbang sambungan pada lapisan keluaran

$W_{jk}$  = Nilai penimbang sambungan dari  $Z_j$  ke unit  $Y_k$

Kalikan nilai ini dengan turunan fungsi aktivasinya untuk menghitung informasi *error* dengan persamaan berikut.

$$\delta_j = \delta_{in_j} f'(Z_{in_j}) = \delta_{in_j} Z_j (1 - Z_j) \quad (3.13)$$

Keterangan:

$\delta_j$  = Faktor pengaturan nilai penimbang sambungan pada lapisan keluaran

$\delta_{in_j}$  = Jumlah kesalahan dari unit tersembunyi

$Z_j$  = Unit ke- $j$  pada lapisan tersembunyi

Kemudian hitung koreksi bobot (digunakan untuk memperbaiki  $V_{ij}$ ) menggunakan persamaan berikut.

$$\Delta V_{ij} = \alpha \delta_j X_i \quad (3.14)$$

Keterangan:

$\Delta V_{ij}$  = Selisih antara  $V_{ij}(t)$  dengan  $V_{ij}(t + 1)$

$\alpha$  = Konstanta laju pelatihan (*learning rate*)

$\delta_j$  = Faktor pengaturan nilai penimbang sambungan pada lapisan tersembunyi

$X_i$  = Nilai aktivasi dari unit  $X_i$

Hitung juga koreksi bias (digunakan untuk memperbaiki  $V_{0j}$ ) menggunakan persamaan berikut.

$$\Delta V_{0j} = \alpha \delta_j \quad (3.15)$$

Keterangan:

$\Delta V_{0j}$  = Selisih antara  $V_{0j}(t)$  dengan  $V_{0j}(t + 1)$

$\alpha$  = Konstanta laju pelatihan (*learning rate*)

$\delta_j$  = Faktor pengaturan nilai penimbang sambungan pada lapisan tersembunyi.

### Fase 3 Perubahan Bobot dan Bias

Langkah 8 : Tiap unit di *output layer* ( $Y_k, k = 1,2,3, \dots, m$ ) melakukan perbaikan bias dan bobotnya ( $j = 0,1,2,3, \dots, p$ ) menggunakan persamaan berikut ini:

$$W_{jk}(\text{baru}) = W_{jk}(\text{lama}) + \Delta W_{jk} \quad (3.16)$$

Keterangan:

$W_{jk}$  = Nilai penimbang sambungan dari  $Z_j$  ke unit  $Y_k$

$\Delta W_{jk}$  = Selisih antara  $W_{jk}(t)$  dengan  $W_{jk}(t + 1)$

Setiap unit di *hidden layer* ( $Z_j, j = 1, 2, 3, \dots, p$ ) melakukan perubahan bobot dan bias yang berasal dari tiap unit di *input layer* ( $X_i, i = 1, 2, 3, \dots, n$ ) menggunakan persamaan sebagai berikut.

$$V_{ij}(\text{baru}) = V_{ij}(\text{lama}) + \Delta V_{ij} \quad (3.17)$$

Keterangan:

$V_{ij}$  = Nilai penimbang sambungan dari  $X_i$  ke unit  $Z_j$

$\Delta V_{ij}$  = Selisih antara  $V_{ij}(t)$  dengan  $V_{ij}(t + 1)$

Untuk mendapatkan karakteristik *backpropagation* yang terbaik sehingga *backpropagation* mampu mempelajari pola yang diberikan dengan benar, maka pelatihan pola dilakukan secara berulang-ulang menggunakan data pelatihan dan parameter yang telah ditentukan.

### 3.9 Support Vector Machine

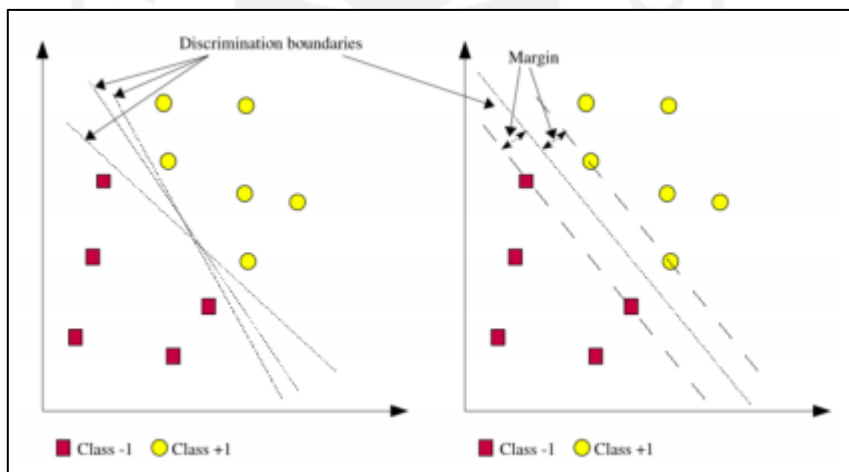
*Support Vector Machine* (SVM) adalah sistem pembelajaran terbimbing yang pengklasifikasiannya menggunakan ruang hipotesis berupa fungsi-fungsi linear dalam sebuah ruang fitur berdimensi tinggi yang dilatih menggunakan algoritma pembelajaran berdasarkan pada teori optimasi dengan mengimplementasikan *learning bias* (Santosa B. , 2007). SVM dikembangkan untuk memecahkan masalah klasifikasi karena SVM memiliki kemampuan yang lebih baik dalam menggeneralisasi data bila dibandingkan dengan teknik yang sudah ada sebelumnya. Pendekatan menggunakan SVM memiliki banyak manfaat seperti model yang dibangun memiliki ketergantungan eksplisit pada subset dari datapoints, serta *support vector* yang membantu dalam interpretasi model (Ningrum, 2018).

Pada dasarnya SVM memiliki prinsip linear, tetapi SVM telah berkembang sehingga dapat bekerja pada masalah non-linear. Cara kerja SVM pada masalah non-linear adalah dengan memasukkan konsep kernel pada ruang berdimensi tinggi. Pada

ruang yang berdimensi ini, nantinya akan dicari pemisah atau sering disebut *hyperplane* (Yahya, 2018). *Hyperplane* dapat memaksimalkan jarak atau *margin* antara kelas data. *Hyperplane* terbaik antara kedua kelas dapat ditemukan dengan mengukur *margin* dan mencari titik maksimalnya. Usaha dalam mencari *hyperplane* yang terbaik sebagai pemisah kelas-kelas adalah inti dari proses pada metode SVM (Assaffat, 2015).

### 3.9.1 Linear Support Vector Machine

Konsep SVM adalah usaha mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua buah kelas pada *input space*. Pada Gambar 3.7 memperlihatkan beberapa *pattern* yang merupakan anggota dari dua buah kelas yaitu +1 dan -1. *Pattern* yang tergabung pada kelas -1 disimbolkan dengan kotak merah, sedangkan *pattern* pada kelas +1 disimbolkan dengan lingkaran kuning (Nugroho, 2007).



**Gambar 3. 7 SVM Linear**  
 Sumber : (Nugroho, 2007)

Gambar 3.7 menjelaskan bahwa SVM berusaha menemukan *hyperplane* terbaik yang memisahkan kedua kelas dengan mengukur *margin hyperplane* dan mencari titik maksimalnya. *Margin* adalah jarak antara *hyperplane* tersebut dengan *pattern* terdekat dari masing-masing kelas. *Pattern* yang paling dekat ini disebut sebagai *support vector*. Masalah klasifikasi dapat diterjemahkan dengan usaha menemukan garis (*hyperplane*) yang memisahkan antara dua kelas tersebut. Garis

solid pada Gambar 3.7 sebelah kanan menunjukkan *hyperplane* yang terbaik, yaitu terletak tepat pada tengah-tengah kedua kelas, sedangkan titik merah dan kuning yang berada dalam lingkaran hitam yang berpotongan dengan garis putus-putus adalah *support vector*. Usaha untuk mencari lokasi *hyperplane* ini merupakan inti dari proses pembelajaran pada SVM (Nugroho, 2007).

Tiap data dinotasikan sebagai  $x_i \in R^d, i = 1, 2, \dots, N$ .  $N$  adalah banyaknya data. *Positive class* dinotasikan sebagai  $+1$ , dan *negative class* sebagai  $-1$ . Dengan demikian, tiap data dan label *class*-nya dinotasikan sebagai  $y_i \in \{-1, +1\}$ . Diasumsikan bahwa kedua kelas tersebut dapat dipisahkan secara sempurna oleh *hyperplane* di  $p$ -dimensional feature space. *Hyperplane* tersebut didefinisikan sebagai berikut:

$$w \cdot x_i + b = 0 \quad (3.18)$$

Data *pattern*  $x_i$  yang tergolong ke dalam *negative class* adalah mereka yang memenuhi pertidaksamaan berikut:

$$w \cdot x_i + b \leq -1 \quad (3.19)$$

Data  $x_i$  yang tergolong ke dalam *positive class* adalah mereka yang memenuhi pertidaksamaan berikut:

$$w \cdot x_i + b \geq 1 \quad (3.20)$$

Keterangan:

$w$  : vektor bobot

$x$  : nilai masukan atribut

$b$  : bias

*Optimal margin* dihitung dengan memaksimalkan jarak antara *hyperplane* dan *pattern* terdekat. Jarak ini dirumuskan sebagai  $\frac{1}{\|w\|}$  dimana  $\|w\|$  adalah norm dari *weight vector*  $w$ . Hal tersebut dirumuskan sebagai *Quadratic Programming* (QP) *Problem* dengan mencari titik minimal seperti persamaan berikut:

$$\min_w \tau(w) = \frac{1}{2} \|w\|^2 \quad (3.21)$$

Kedalam:

$$y_i(w \cdot w_i + b) - 1 \geq 0, \forall_i \quad (3.22)$$

Optimisasi ini dapat diselesaikan dengan *Lagrange Multipliers*, yaitu metode untuk menemukan harga atau nilai minimum atau maksimum relatif dari suatu fungsi:

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i y_i (w \cdot w_i + b - 1) \quad (3.23)$$

$\alpha_i$  adalah *Lagrange Multiplier* yang berkorespondensi dengan nilai  $x_i$ . Nilai  $\alpha_i$  adalah nol atau positif  $\alpha_i \geq 0$ . Untuk menyelesaikan masalah tersebut, harus meminimalkan  $L$  terhadap  $w$ , dan memaksimalkan  $L$  terhadap  $\alpha_i$ .  $\forall_i$  untuk semua anggota  $i$ . *Maximization problem* dapat direpresentasikan dalam  $\alpha_i$  dengan persamaan berikut:

$$\sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j x_i x_j \quad (3.24)$$

Subjek menjadi:

$$\alpha_i \geq 0, \sum_{i=1}^N \alpha_i y_i = 0 \quad (3.25)$$

Solusi dari problem ini akan menghasilkan banyak  $\alpha_i$  dengan nilai nol. Data yang berkorespondensi dengan  $\alpha_i$  yang tidak nol, merupakan *support vector*, yaitu data yang memiliki jarak terdekat dengan *hyperplane* (Nugroho, 2007).

### 3.9.2 Soft Margin

Pada umumnya kedua belah kelas tidak dapat terpisah secara sempurna. Hal ini menyebabkan proses optimisasi tidak dapat diselesaikan. Ketika data yang digunakan tidak dapat dipisahkan, *slack variables*  $x_i$  diperkenalkan kedalam fungsi SVM untuk memungkinkan kesalahan dalam misklasifikasi. Untuk itu perlu modifikasi pertidaksamaan dengan memasukkan *slack variable* menjadi berikut:

$$y_i(w \cdot w_i + b) \geq 1 - \xi_i \forall_i \quad (3.26)$$

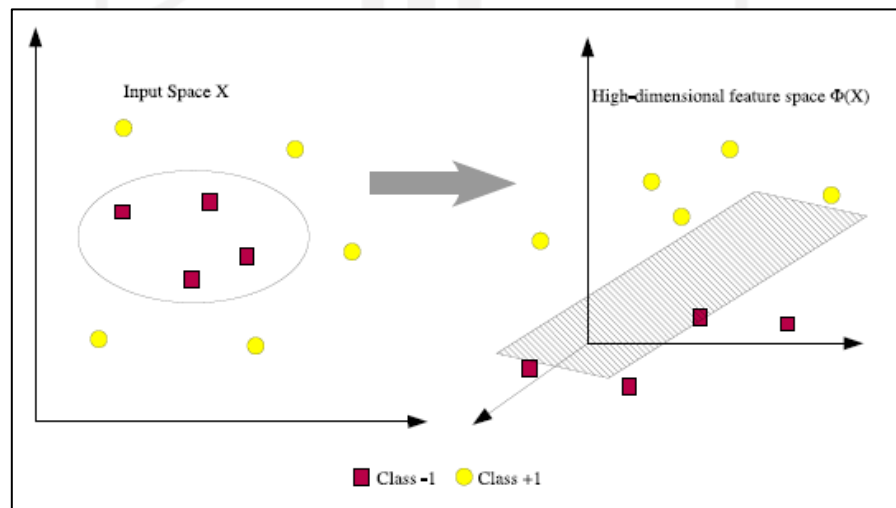
Modifikasi pertidaksamaan juga dilakukan pada rumus minimal, sehingga diperoleh:

$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad (3.27)$$

Parameter  $C$  bertugas untuk mengontrol *tradeoff* antara *margin* and *classification error*. Semakin besar nilai  $C$  semakin besar penalti yang dikenakan untuk setiap *classification error*. Apabila nilai  $C$  besar, SVM akan mencoba menemukan *hyperplane* dan *margin*, sehingga ada beberapa *pattern* dalam *margin* yang memiliki model terlalu kompleks dengan hanya memiliki *margin* kecil dan *pattern* tidak mudah dipisahkan. Sedangkan, apabila nilai  $C$  kecil maka akan memberikan kesalahan yang lebih tinggi pada *training*. Parameter *gamma* ( $\gamma$ ) digunakan untuk mentransformasikan data *training* ke ruang fitur yang kemudian dioptimasi sehingga menghasilkan nilai  $\alpha$  yang digunakan untuk menentukan *support vector* dan memperkirakan koefisien bobot dan bias pada model klasifikasi.

### 3.9.3 Non-Linear Support Vector Machine

Pada klasifikasi *non-linear*, data yang berada pada sebuah ruang vektor awal harus dipindahkan ke dalam ruang vektor baru yang dimensinya lebih tinggi. Contoh, fungsi pemetaan dinotasikan sebagai  $\phi(x)$ . Mempresentasikan data ke format yang dipisahkan secara linear pada ruang vektor baru merupakan tujuan dari pemetaan.



**Gambar 3. 8 SVM Non-linear**

Sumber : (Nugroho, 2007)


Fungsi  $\phi$  adalah memetakan data ke ruang vektor yang berdimensi lebih tinggi, sehingga kedua buah kelas dapat dipisahkan secara linear oleh sebuah



*hyperplane*. Pada Gambar 3.8, diperlukan sebuah perhitungan *dot product* dua buah contoh pada ruang vektor baru pada fase tersebut. Dinotasikan dengan  $\phi(x_i)$ ,  $\phi(x_j)$  untuk *dot product* kedua buah *vector*  $x_i$  dan  $x_j$ . Secara tidak langsung nilai *dot product* kedua vektor tersebut bisa dihitung dengan cara tidak mengetahui proses transformasi  $\phi$ .

### 3.9.4 Kernel

Ketika terdapat permasalahan data yang tidak terpisah secara linear dalam ruang *input*, *soft margin SVM* tidak dapat menemukan *hyperplane* pemisah yang kuat yang meminimalkan misklasifikasi dari *data points* serta menggeneralisasi dengan baik. Untuk itu, kernel dapat digunakan untuk mentransformasi data ke ruang berdimensi lebih tinggi yang disebut sebagai ruang kernel. Ruang kernel akan menjadikan data terpisah secara linear (Awad & Khanna, 2015).



**Gambar 3. 9** Kernel untuk Memisahkan Data Secara Linear  
Sumber : (Ningrum, 2018)

Data disimpan dalam bentuk kernel yang mengukur kesamaan atau ketidaksamaan objek data. Kernel dapat dibangun untuk berbagai objek data mulai dari data kontinu dan diskrit melalui urutan data dan grafik. Konsep substitusi kernel berlaku bagi metode lain dalam analisis data. Namun, SVM merupakan yang paling terkenal dari metode dengan jangkauan kelas luas yang menggunakan kernel untuk merepresentasikan data dan dapat disebut sebagai metode berbaris kernel (Campbell & Ying, 2011). Berikut merupakan ilustrasi dalam melakukan pemisahan data menggunakan kernel. Diketahui bahwa data terdiri dari *input space* dengan dua buah  $\mathbf{x} = \{x_1, x_2\}$  dan  $\mathbf{z} = \{z_1, z_2\}$ . Diasumsikan fungsi kernel akan dibuat dengan menggunakan *input*  $x$  dan  $z$  seperti berikut:

$$\begin{aligned}
K(x,z) &= (x^T z)^2 \\
K(x,z) &= (x_1 z_1 + x_2 z_2)^2 \\
K(x,z) &= (x_1^2 z_1^2 + x_2^2 z_2^2 + 2x_1 x_2 z_1 z_2)^2 \\
K(x,z) &= (x_1^2, \sqrt{2}x_1 x_2, x_2^2)^T (z_1^2, \sqrt{2}z_1 z_2, z_2^2) \\
K(x,z) &= \phi(x)^T \phi(z) \tag{3.28}
\end{aligned}$$

Nilai K di atas secara implisit mendefinisikan pemetaan ke ruang dimensi yang lebih tinggi seperti berikut:

$$\phi(x) = \{x_1^2, \sqrt{2}x_1 x_2, x_2^2\} \tag{3.29}$$

Kernel  $K(x,z)$  mengambil dua *input space* dan memberikan kesamaannya dalam *feature space* seperti berikut:

$$\begin{aligned}
\phi : X &\rightarrow F \\
K : X \times X &\rightarrow R, K(x, z) = \phi(x) \cdot \phi(z) \tag{3.30}
\end{aligned}$$

Berdasarkan pada fungsi kernel di atas, dapat dilakukan perhitungan untuk melakukan prediksi dari beberapa data dalam *feature space* seperti persamaan berikut (Campbell & Ying, 2011):

$$\begin{aligned}
f(\phi(x)) &= \text{sign}(w \cdot \phi(z) + b) \\
f(\phi(x)) &= \text{sign}(\sum_{i=1}^m \alpha_i y_i K(x, z) + b) \tag{3.31}
\end{aligned}$$

Keterangan:

- $b$  = nilai bias
- $m$  = jumlah *support vector*
- $K(x,z)$  = fungsi kernel

Nilai  $k$  yang bisa digunakan sebagai fungsi kernel harus memenuhi kondisi Mercer antara lain (Ningrum, 2018):

- Merupakan *Hilbert Space* dimana nilai *feature space* harus merupakan vektor dengan *dot production*
  - Harus benar jika  $k$  merupakan fungsi definit positif
- $$\int dx \int dz f(x) K(x, z) f(z) > 0 \quad (\forall f \in L_2) \tag{3.32}$$
- Ketika  $k_1$  dan  $k_2$  merupakan fungsi kernel, maka:

$$K(x,z) = K_1(x,z) + K_2(x,z) : \text{Direct sum}$$

$$K(x,z) = \alpha K_1(x,z) : \text{Skalar Product}$$

$$K(x,z) = K_1(x,z)K_2(x,z) : \text{Direct Product}$$

Beberapa macam kernel SVM yang sering digunakan sebagai berikut:

**Tabel 3. 1** Kernel SVM yang Sering Digunakan

Nama Kernel	Fungsi
RBF	$K(x,z) = \exp[-\gamma\ x-z\ ^2]$
Sigmoid	$K(x, x_k) = \tanh[\kappa x_k^T x + \theta]$

### 3.10 Confusion Matrix

*Confusion Matrix* adalah suatu metode yang biasanya digunakan untuk melakukan perhitungan akurasi pada konsep *data mining*. *Confusion matrix* digambarkan dengan tabel yang menyatakan jumlah data uji yang benar diklasifikasikan dan jumlah data uji yang salah diklasifikasikan (Rahman, Darmawidjadja, & Alamsah, 2017).

**Tabel 3. 2** Confusion Matrix

	Actually Positive (1)	Actually Negative
Predicted Positive (1)	True Positive (TP)	False Positive (FP)
Predicted Negative (1)	False Negative (FN)	True Negative (TN)

Berdasarkan tabel *confusion matrix* diatas :

- True Positive* (TP) adalah jumlah *record* data positif yang diklasifikasikan sebagai nilai positif.
- False Positive* (FP) adalah jumlah *record* data negatif yang diklasifikasikan sebagai nilai positif.
- False Negative* (FN) adalah jumlah *record* data positif yang diklasifikasikan sebagai nilai negatif.
- True Negative* (TN) adalah jumlah *record* data negatif yang diklasifikasikan sebagai nilai negatif.

## **BAB IV**

### **METODOLOGI PENELITIAN**

#### **4.1 Populasi dan Sampel Penelitian**

Populasi dalam penelitian ini adalah seluruh perusahaan sektor pertambangan di Indonesia.

Pemilihan sampel dilakukan berdasarkan metode *purposive sampling*, yaitu pemilihan sampel berdasarkan kriteria tertentu dan peluang objek penelitian terambil tidak sama. Sampel yang digunakan dibagi menjadi 2 kriteria, yaitu perusahaan yang mengalami *financial distress* dan perusahaan yang tidak mengalami *financial distress* atau *non financial distress*.

- a. Perusahaan pertambangan yang mengalami *financial distress* sebanyak 6 perusahaan, dengan kriteria :
  - 1) Perusahaan sektor pertambangan yang terdaftar di Bursa Efek Indonesia dan menerbitkan laporan keuangan periode 2017-2018.
  - 2) Perusahaan yang mengalami *earning per share* negatif selama 2 tahun terakhir.
- b. Perusahaan pertambangan yang tidak mengalami *financial distress* sebanyak 32 perusahaan, dengan kriteria :
  - 1) Perusahaan sektor pertambangan yang terdaftar di Bursa Efek Indonesia dan menerbitkan laporan keuangan periode 2017-2018.
  - 2) Perusahaan yang mengalami *earning per share* positif selama 2 tahun terakhir (Curry & Banjarnahon, 2018).

#### **4.2 Tempat dan Waktu Penelitian**

Pengambilan data dari Bursa Efek Indonesia yang dapat diakses melalui [www.idx.co.id](http://www.idx.co.id). Waktu pengambilan data dilakukan pada bulan Maret 2020.

#### **4.3 Jenis penelitian**

Jenis penelitian yang dilakukan berupa statistika deskriptif dan analisis terkait memprediksi *financial distress* terhadap perusahaan pertambangan yang ada di

Indonesia. Analisis *financial distress* ini menggunakan metode *Artificial Neural Network* dan *Support Vector Machine*. Dari kedua metode tersebut akan dibandingkan berdasarkan nilai akurasi yang didapatkan dari *confusion matrix*.

#### **4.4 Data dan Variabel Penelitian**

Data yang digunakan dalam penelitian ini adalah data sekunder mengenai rasio keuangan perusahaan sektor pertambangan tahun 2017-2018 di Indonesia. Rasio keuangan yang digunakan adalah *working capital/total asset*, *retained earning/total asset*, *earning before interest and tax/total asset*, dan *market value/total liabilities* (Altman, 1968). Rasio keuangan tersebut adalah rasio yang digunakan dalam penelitian Altman.

Penelitian ini menggunakan variabel dependen dan variabel independen, sebagai berikut:

##### **4.4.1 Variabel Dependen**

Variabel dependen yang digunakan dalam penelitian ini adalah kondisi *financial distress* dari sebuah perusahaan. Variabel yang digunakan akan dikategorikan menjadi 0 dan 1, maka dibuat variabel buatan (*dummy/binary variable*). Kode 0 menunjukkan kondisi perusahaan tidak mengalami *financial distress*, sedangkan kode 1 menunjukkan kondisi perusahaan mengalami *financial distress*.

##### **4.4.2 Working Capital/Total Asset ( $X_1$ )**

*Working capital/total asset* atau modal kerja/total aktiva pada dasarnya adalah salah satu rasio likuiditas yang mengukur kemampuan perusahaan dalam memenuhi kewajiban jangka pendek. Modal kerja yang dimaksud dalam  $X_1$  adalah selisih antara aktiva lancar dengan utang lancar. Hasil rasio dapat negatif apabila aktiva lancar lebih kecil dari utang lancar. Variabel ini dapat mendeteksi adanya masalah pada tingkat likuiditas perusahaan seperti ketidakcukupan kas, utang dagang membengkak, harta kekayaan menurun, penambahan utang yang tak terkendali, dan beberapa lainnya. Semakin kecil nilai  $X_1$  akan meningkatkan potensi *financial distress* begitu juga

sebaliknya, semakin besar nilai  $X_1$  akan menurunkan potensi *financial distress* (Aprylia, 2016). Rasio likuiditas ini diukur dengan:

$$WCTA = \frac{Working\ Capital}{Total\ Asset}$$

#### **4.4.3 Retained Earning/Total Asset ( $X_2$ )**

*Retained earning/total asset* atau laba ditahan/total aktiva ini mengukur akumulasi laba selama perusahaan beroperasi. Umur perusahaan berpengaruh pada rasio ini, semakin lama perusahaan beroperasi memungkinkan untuk memperlancar akumulasi laba ditahan (Agustina & Rahmawati, 2010). Jadi, semakin kecil nilai rasio  $X_2$  akan meningkatkan potensi *financial distress* dan sebaliknya, semakin besar nilai rasio  $X_2$  akan menurunkan potensi *financial distress* (Aprylia, 2016). Rasio ini diukur dengan:

$$RETA = \frac{Retained\ Earnings}{Total\ Asset}$$

#### **4.4.4 Earning Before Interest and Tax/Total Asset ( $X_3$ )**

*Earning before interest and tax/total asset* atau laba sebelum bunga dan pajak/total aktiva ini mengukur kemampuan perusahaan dalam menghasilkan laba dari aktiva yang digunakan. Rasio ini untuk mendeteksi adanya masalah pada kemampuan profitabilitas, yaitu untuk mengukur kemampuan perusahaan menghasilkan keuntungan pada tingkat penjualan, aset, dan mode saham tertentu atau digunakan untuk mengukur seberapa efektif pengelolaan perusahaan sehingga menghasilkan keuntungan. Semakin kecil nilai rasio akan meningkatkan potensi *financial distress* dan sebaliknya, semakin besar nilai rasio akan menurunkan potensi *financial distress* (Andhito, 2011). Rasio ini diukur dengan:

$$EBITA = \frac{Earning\ Before\ Interest\ and\ Tax}{Total\ Asset}$$

#### **4.4.5 Market Value Equity/Total Liabilities ( $X_4$ )**

Rasio solvabilitas merupakan salah satu variabel independen yang digunakan. Rasio ini mengukur kemampuan perusahaan memenuhi kewajiban jangka panjangnya. Semakin besar nilai rasio solvabilitas akan meningkatkan potensi

*financial distress* dan sebaliknya, semakin kecil nilai rasio akan menurunkan potensi *financial distress*. Rasio ini diukur dengan:

$$MVETL = \frac{\text{Market Value Equity}}{\text{Total Liabilities}}$$

#### 4.5 Metode Analisis

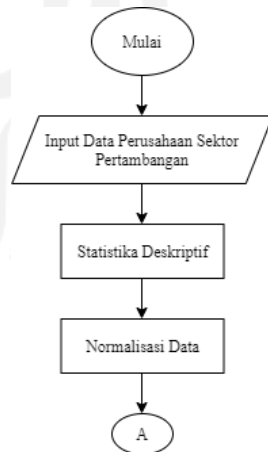
Metode yang digunakan dalam penelitian ini adalah statistika deskriptif, *Artificial Neural Network*, dan *Support Vector Machine*. Statistika deskriptif digunakan untuk memberikan gambaran umum dari data laporan keuangan dengan rasio-rasio yang sudah ditentukan. Sedangkan metode *Artificial Neural Network* dan *Support Vector Machine* digunakan untuk membedakan dua atau lebih kelompok berdasarkan beberapa variabel independen. Hasil dari metode *Artificial Neural Network* dan *Support Vector Machine* akan dibandingkan dengan melihat akurasi menggunakan metode *Confusion Matrix*. Metode dengan nilai akurasi lebih besar maka dapat disimpulkan bahwa metode tersebut lebih baik digunakan dalam memprediksi *financial distress* perusahaan. Kemudian akan ditentukan metode yang terbaik untuk melakukan analisis kebangkrutan dari data sektor pertambangan di Indonesia pada tahun 2017-2018.

#### 4.6 Tahapan Penelitian

Dalam penelitian diperlukan sebuah alur penelitian atau diagram alur yang dijadikan sebuah acuan dalam proses penelitian. Penelitian ini dilakukan dengan beberapa tahapan sesuai dengan *flowchart* pada Gambar 4.1. Tahapan-tahapan tersebut antara lain :

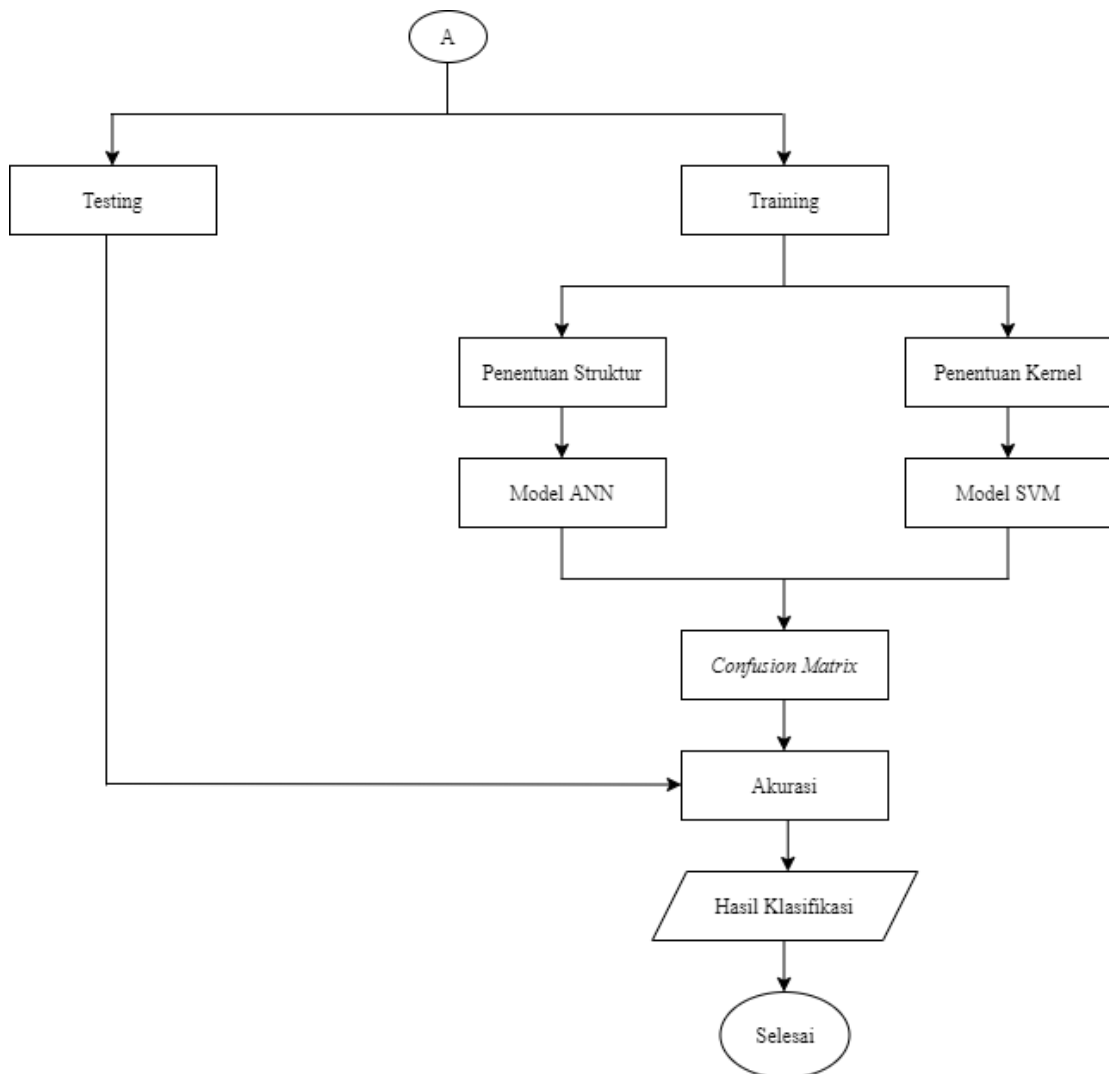
1. Melakukan *input* data yang sudah diambil dari *website* Bursa Efek Indonesia. Data yang di-*input* adalah data *working capital/total asset*, *retained earning/total asset*, *earning before interest and tax/total asset*, dan *market value equity/total liabilities*.
2. Melakukan analisis statistika deskriptif untuk menggambarkan keadaan data yang digunakan dalam penelitian. Hasil analisis ditampilkan dalam bentuk histogram.

3. Melakukan normalisasi agar ada perubahan rentang dari nilai atribut. Normalisasi memberikan hasil yang lebih baik, rentang nilai atribut yang dianjurkan untuk digunakan adalah 0 sampai 1.
4. Membagi data menjadi 2 bagian yaitu data *training* dan data *testing*. Proporsi data *training* lebih besar dibandingkan data *testing*. Data *training* digunakan melatih data dalam membentuk model, sedangkan data *testing* digunakan untuk memprediksi dan melihat keakuratan model yang terbentuk.
5. Dari data *training* akan dilakukan penentuan struktur untuk metode *Artificial Neural Network* dan penentuan kernel untuk metode *Support Vector Machine*.
6. Dari penentuan struktur akan didapatkan model dari *Artificial Neural Network* dan dari penentuan kernel akan didapatkan model *Support Vector Machine*.
7. Melakukan *confusion matrix* untuk mengetahui nilai akurasi dari metode *Artificial Neural Network* dan *Support Vector Machine*.
8. Menghitung nilai akurasi menggunakan data *testing*, akurasi yang lebih baik dari kedua metode tersebut adalah metode yang lebih baik untuk melakukan penelitian prediksi *financial distress*.
9. Mendapatkan hasil dari klasifikasi yang telah dilakukan.



**Gambar 4. 1** *Flowchart*



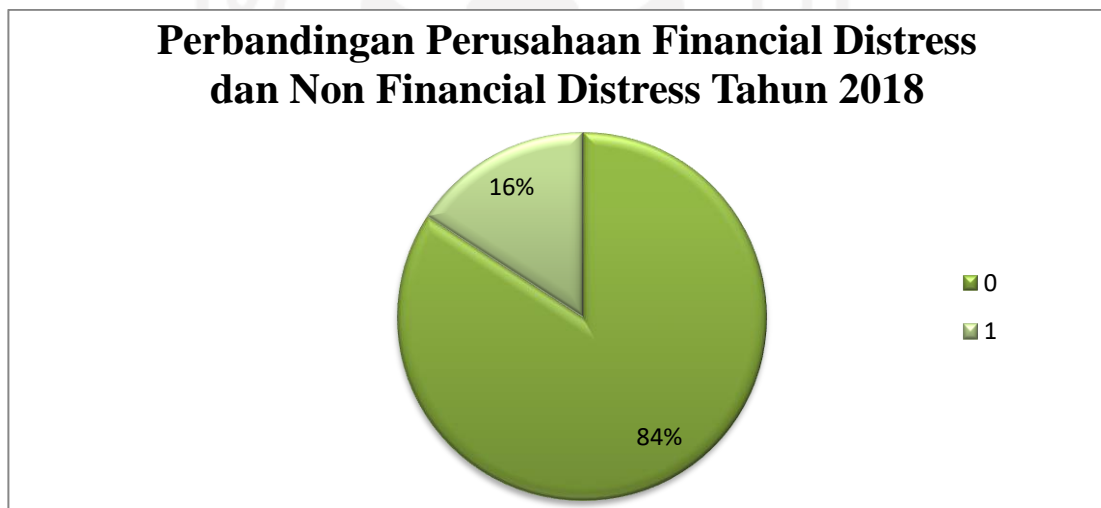


**Gambar 4. 2** *Flowchart*

## BAB V HASIL DAN PEMBAHASAN

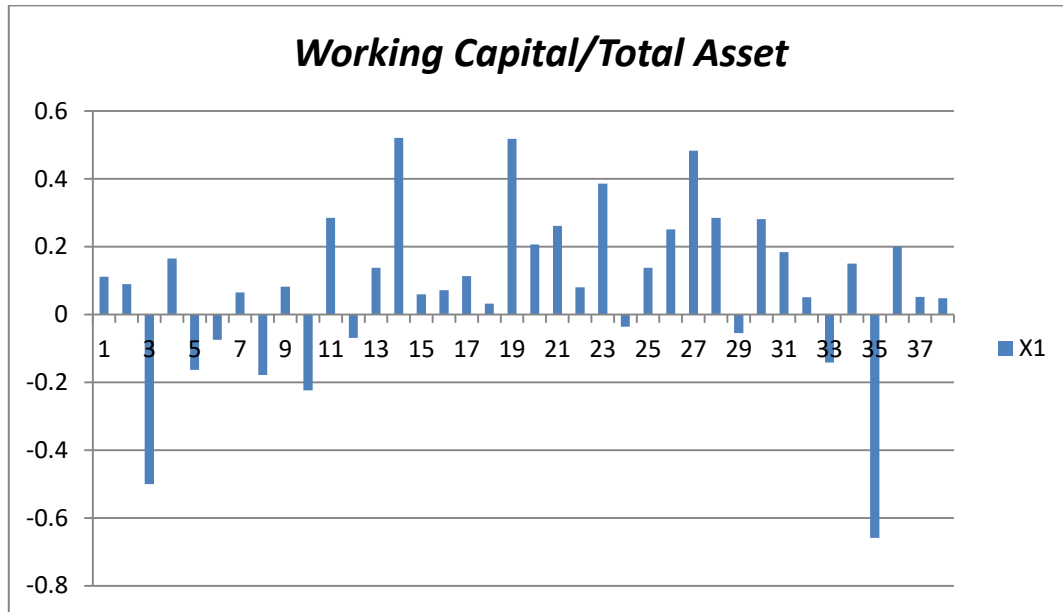
### 5.1 Statistika Deskriptif

Data dalam penelitian ini adalah data sekunder yang diambil dari [www.idx.co.id](http://www.idx.co.id) yang akan dilakukan analisis menggunakan metode *Support Vector Machine* dan *Artificial Neural Network*. Sebelum membandingkan kedua metode tersebut, peneliti akan melakukan statistika deskriptif dari rasio keuangan atau variabel yang digunakan. Analisis deksriptif digunakan untuk menggambarkan variabel yang digunakan, seperti *working capital/total asset*, *retained earnings/total asset*, *earning before interest and tax/total asset*, dan *market value equity/total liabilities*.



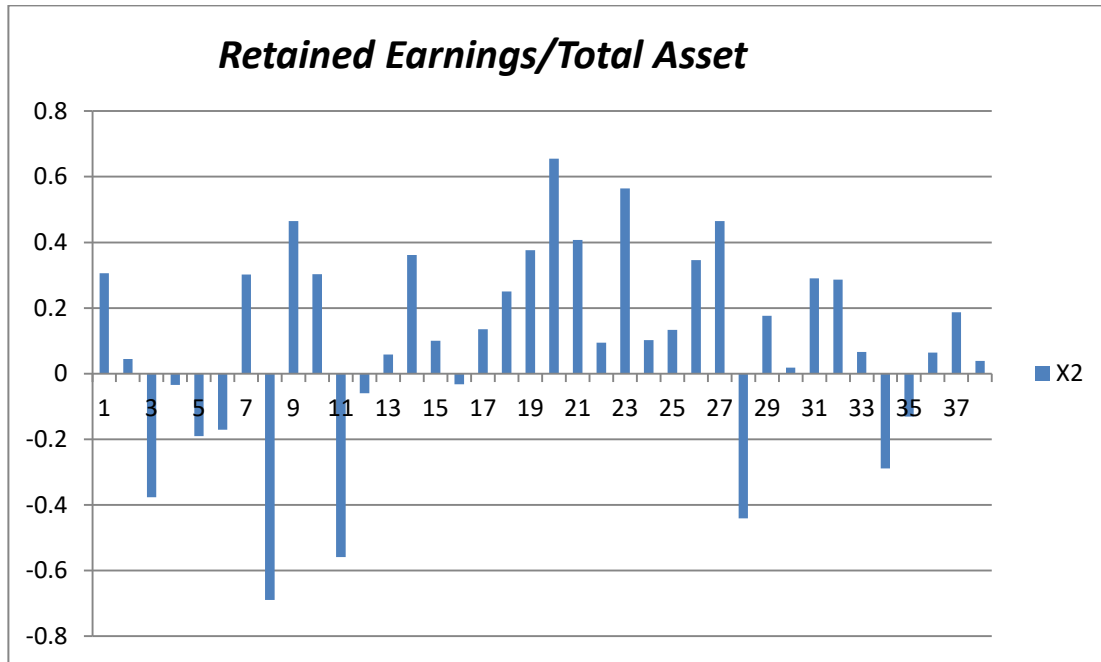
**Gambar 5. 1** Perbandingan Perusahaan Financial Distress

Data yang digunakan adalah data perusahaan sektor pertambangan sebanyak 38 perusahaan yang dibedakan menjadi perusahaan *financial distress* dan *non financial distress*. Dari Gambar 5.1 dapat dilihat perusahaan yang tidak mengalami *financial distress* atau *non financial distress* ditandai dengan “0” terdiri dari 32 perusahaan atau 84% dan perusahaan yang mengalami *financial distress* ditandai dengan “1” terdiri dari 6 perusahaan atau 16%.



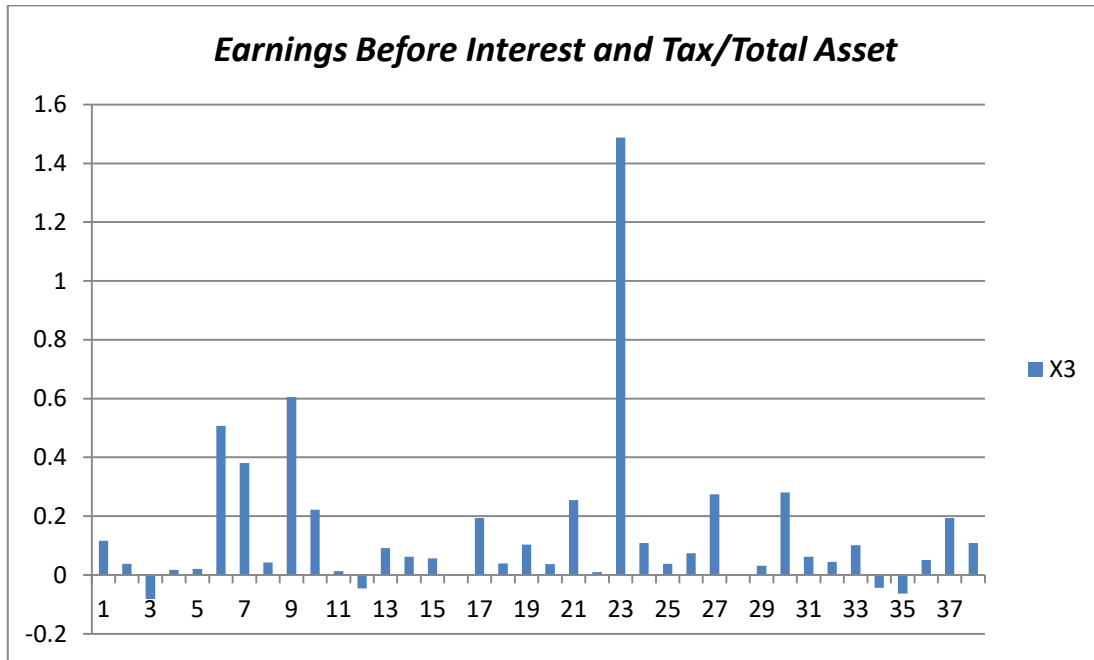
**Gambar 5. 2** Histogram Variabel *Working Capital/Total Asset*

Gambar 5.2 menggambarkan data  $X_1$  yaitu variabel rasio *working capital/total asset*.  $X_1$  memiliki nilai minimum sebesar -0.65891 yaitu perusahaan PT. Super Energy Tbk dan nilai maksimum sebesar 0.520884 yaitu perusahaan PT. Elnusa Tbk. Rasio ini menunjukkan kemampuan perusahaan untuk menghasilkan modal kerja dari keseluruhan total aset yang dimilikinya. Rasio ini dihitung dengan membagi modal kerja dengan total aset, dimana modal kerja didapatkan dengan cara total aset lancar dikurangi dengan kewajiban lancar. Modal kerja yang negatif kemungkinan besar akan menghadapi masalah dalam menutupi kewajiban lancar karena tidak tersedianya aset lancar yang cukup untuk menutupi kewajiban tersebut, begitu juga sebaliknya. Sehingga, jika suatu perusahaan memiliki nilai rasio *working capital/total asset* negatif, maka perusahaan tersebut mempunyai kemungkinan besar akan mengalami *financial distress*. Semakin kecil nilai rasio *working capital/total asset* akan meningkatkan potensi terjadinya *financial distress*.



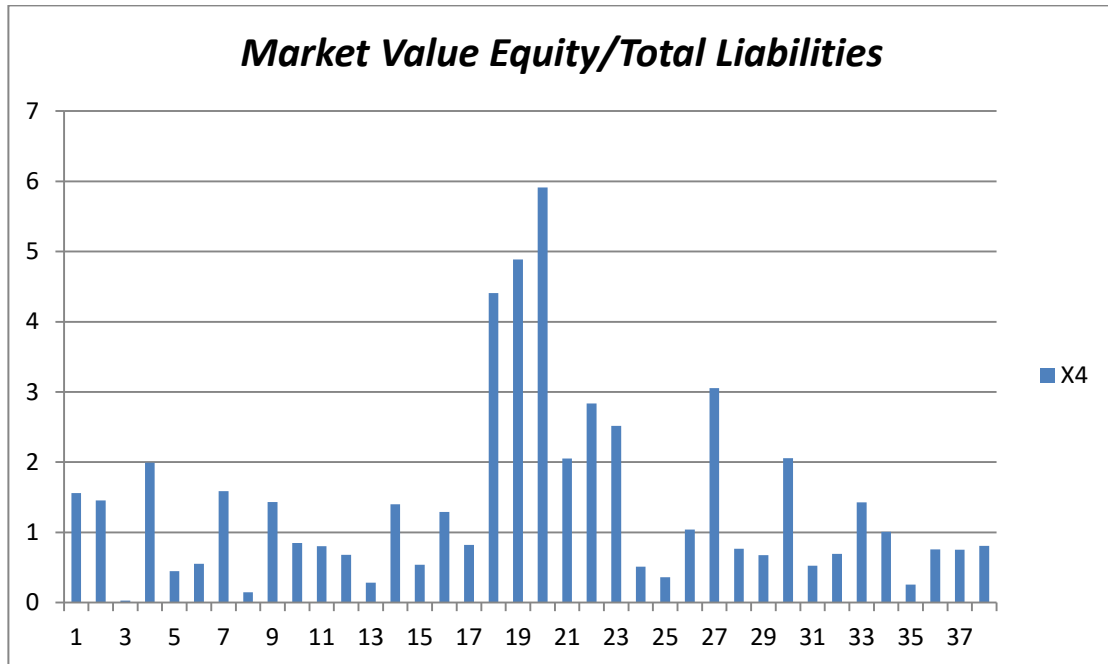
**Gambar 5. 3** Histogram Variabel *Retained Earnings/Total Asset*

Gambar 5.3 menggambarkan data  $X_2$  yaitu variabel rasio *retained earnings/total asset*.  $X_2$  memiliki nilai minimum sebesar -0.69003 yaitu perusahaan PT. Bumi Resources Tbk dan nilai maksimum sebesar 0.65485 yaitu perusahaan PT. Vale Indonesia Tbk. Rasio ini menunjukkan kemampuan perusahaan untuk menghasilkan laba ditahan dari total aset perusahaan. *Retained earnings* atau laba ditahan adalah laba yang tidak dibagikan kepada para pemegang saham. Rasio ini merupakan indikator profitabilitas kumulatif yang relatif terhadap panjangnya waktu yang mengisyaratkan bahwa semakin muda suatu perusahaan semakin sedikit waktu yang dimilikinya untuk membangun laba kumulatif, sehingga semakin besar kemungkinannya untuk mengalami kegagalan usaha. Jika perusahaan merugi, nilai laba ditahan pada perusahaan tersebut akan mengalami penurunan. Semakin kecil nilai rasio *retained/total asset* akan meningkatkan potensi terjadinya *financial distress*.



**Gambar 5.4** Histogram Variabel *Earnings before Interest and Tax/Total Asset*

Gambar 5.4 menggambarkan data  $X_3$  yaitu variabel rasio *earnings before interest and tax/total asset*.  $X_3$  memiliki nilai minimum sebesar -0.08218 yaitu perusahaan PT. Atlas Resources Tbk dan nilai maksimum sebesar 1.48775 yaitu perusahaan PT. Mitrabara Adiperdana Tbk. Rasio ini menunjukkan kemampuan perusahaan untuk menghasilkan laba dari aset perusahaan, sebelum melakukan pembayaran bunga dan pajak. Melemahnya rasio ini adalah indikator terbaik akan terjadinya kebangkrutan. Semakin kecil nilai rasio *earnings before interest and tax/total asset* akan meningkatkan potensi *financial distress*.



**Gambar 5.5** Histogram Variabel *Market Value Equity/Total Liabilities*

Gambar 5.5 menggambarkan data  $X_4$  yaitu variabel rasio *market value equity/total liabilities*.  $X_4$  memiliki nilai minimum sebesar 0.02936 yaitu perusahaan PT. Atlas Resources Tbk dan nilai maksimum sebesar 5.91019 yaitu perusahaan PT. Vale Indonesia Tbk. Rasio ini menunjukkan kemampuan perusahaan untuk memenuhi kewajiban dari nilai pasar modal sendiri (saham biasa). Nilai pasar ekuitas diperoleh dengan mengalikan jumlah lembar saham yang beredar dengan harga pasar per lembar saham. Nilai buku utang diperoleh dengan menjumlahkan kewajiban lancar dengan kewajiban jangka panjang. Semakin kecil nilai rasio *market value equity/total liabilities* akan menurunkan potensi *financial distress*.

## 5.2 Normalisasi Data

Dilakukannya normalisasi data yaitu untuk mengubah skala pengukuran data asli menjadi bentuk data baru yang skala datanya memiliki nilai yang sama. Normalisasi yang digunakan adalah *min-max normalization* supaya data hasil normalisasi linier dengan data asli dan *range* yang digunakan adalah 0 sampai 1.

Y	x1	x2	x3	x4
0	0.6525945	0.7406816	0.12640892	0.26028348
0	0.6345052	0.5460744	0.07654634	0.24240950
1	0.1347825	0.2328604	0.00000000	0.00000000
0	0.6984300	0.4874630	0.06317752	0.33399121
0	0.4204575	0.3714751	0.06577607	0.07129499
0	0.4955600	0.3860726	0.37554087	0.08881958

**Gambar 5. 6** Data Setelah Ditransformasi

### 5.3 *Balancing Data*

Data yang akan diolah untuk analisis terdiri dari dua kelas, yaitu *financial distress* dan *non financial distress* dengan jumlah masing-masing kelas sebanyak 32 dan 6. Perbandingan data antara dua kelas tersebut sangat jauh, sehingga data dikatakan *imbalance* atau tidak seimbang. Untuk mengatasi permasalahan tersebut, peneliti menggunakan metode *oversampling* dengan cara membangkitkan data minoritas sebanyak data mayoritas, sehingga nilai akurasi yang didapatkan dari metode SVM dan ANN lebih maksimal.

Pada penelitian ini jumlah kelas yang besar terdapat pada kelas *non financial distress* dan jumlah kelas yang kecil terdapat pada kelas *financial distress*. Sehingga *oversampling* bekerja dengan membangkitkan data pada kelas *financial distress* sebanyak dengan kelas *financial distress*.

**Tabel 5. 1** *Balancing Data*

<i>Financial Distress</i>	<i>Non Financial Distress</i>
32	32

### 5.4 *Pembagian Data Training dan Testing*

Data akan diklasifikasikan menjadi dua yaitu data *training* dan data *testing*. Data *training* digunakan untuk melatih algoritma sehingga mendapatkan model, sedangkan data *testing* digunakan untuk menguji model yang didapatkan. Hal ini berguna untuk menemukan akurasi permodelan yang baik. Pembagian data *training* dan data *testing* ini dilakukan secara acak dengan menggunakan perbandingan 75% untuk data *training* dan 25% untuk data *testing*.

Hasil dari pembagian data *training* dan *testing* dapat dilihat pada gambar berikut ini.

**Tabel 5. 2** Pembagian Data *Training* dan *Testing*

<b>Keterangan</b>	<b><i>Training</i></b>	<b><i>Testing</i></b>	<b>Total</b>
<b>Jumlah</b>	48	16	64
<b>Presentase</b>	75%	25%	100%

### 5.5 Metode *Support Vector Machine*

Salah satu metode yang digunakan dalam penelitian ini adalah metode *Support Vector Machine* (SVM). Dalam penggunaan metode SVM ini akan dilakukan pemisahan data antara data *training* dan data *testing*. Proses klasifikasi menggunakan data *training*, sedangkan untuk mendapatkan akurasi menggunakan data *testing*. Dalam mencari nilai akurasi terbaik untuk metode SVM akan digunakan dua fungsi kernel yaitu RBF kernel dan sigmoid kernel.

#### 5.5.1 RBF Kernel

RBF kernel adalah fungsi kernel yang digunakan ketika data terpisah secara linear. Dalam melakukan analisis dengan fungsi RBF, dilakukan optimasi parameter *Cost* (C) dan *Gamma* ( $\gamma$ ). Dalam penentuan parameter terbaik, dilakukan *trial and error*. Peneliti menggunakan uji coba nilai C sebanyak lima kali yaitu 0.1, 1, 5, 10, dan 50, serta uji coba nilai *gamma* sebanyak empat kali yaitu 1, 2, 3, dan 4. Berikut adalah hasil nilai akurasi pada kernel RBF seperti berikut:

**Tabel 5. 3** Nilai Akurasi Parameter Terbaik Kernel RBF

Parameter	Akurasi			
	$\gamma = 1$	$\gamma = 2$	$\gamma = 3$	$\gamma = 4$
C=0.1	0.345	0.345	0.345	0.345
C=1	0.94	0.94	0.96	0.96
C=5	0.94	0.96	0.96	0.96
C=10	0.94	0.96	0.96	0.96
C=50	0.94	0.96	0.96	0.96

Dari keseluruhan *trial and error* yang dilakukan, diperoleh hasil akurasi yang paling besar adalah 0.96 dengan nilai C=5 dan *gamma*=2. Sehingga dalam pembentukan model SVM dengan *training dataset* akan menggunakan nilai parameter C=5 dan *gamma*=2 sebagai parameter terbaik. Berikut adalah parameter model kernel RBF:



**Tabel 5. 4** Parameter Model SVM Kernel RBF

Parameter		
SVM – Type	:	C-Classification
SVM – Kernel	:	Radial
Cost	:	5
Gamma	:	2
Number of Support Vector	:	23

Dari parameter *cost* dan *gamma* di atas, dapat dibuat *confusion matrix* untuk mendapatkan nilai akurasi dari model SVM kernel RBF menggunakan *testing dataset*.

**Tabel 5. 5** *Confusion Matrix* SVM Kernel RBF

Prediksi	Aktual	
	Non FD	FD
Non FD	7	2
FD	0	7

Berdasarkan Tabel 5.5, diperoleh hasil bahwa terdapat dua kemungkinan status perusahaan yaitu *financial distress* atau *non financial distress*. Pada tabel klasifier di atas terdapat 16 prediksi yang diperoleh. Dari 14 sampel di atas, klasifier memprediksi pilihan “non FD” adalah sebanyak 9 kali dan prediksi “FD” adalah sebanyak 7 kali. Sedangkan pada data aktual terdapat 7 perusahaan *non financial distress* sedangkan 9 lainnya *financial distress*. Hasil prediksi bernilai 7 dinamakan sebagai *false positif*, dimana nilai prediksi menyatakan hasil perusahaan *non financial distress* sedangkan aktualnya perusahaan mengalami *financial distress*. Setelah diperoleh *confusion matrix*, dapat dilanjutkan dengan mencari nilai akurasi dari data *testing* menggunakan perhitungan berikut:

$$Akurasi = \frac{TP + TN}{TP + TN + FN + FP}$$

$$Akurasi = \frac{7 + 7}{7 + 2 + 0 + 7} = \frac{14}{16}$$

$$Akurasi = 0.875$$

Diperoleh nilai akurasi klasifikasi sebesar 0.875 atau 88%. Artinya, kemungkinan kesalahan klasifikasi perusahaan *financial distress* sebesar 12%.

### 5.5.2 Sigmoid Kernel

Sigmoid kernel juga memerlukan nilai parameter *cost* dan *gamma*. Pengoptimalisasi parameter dilakukan dengan *trial and error*. Peneliti menggunakan uji coba nilai C sebanyak lima kali yaitu 0.1, 1, 5, 10, dan 50, serta uji coba nilai *gamma* sebanyak empat kali yaitu 1, 2, 3, dan 4. Berikut adalah hasil nilai akurasi pada kernel sigmoid seperti berikut:

**Tabel 5. 6** Nilai Akurasi Parameter Terbaik Kernel Sigmoid

Parameter	Akurasi			
	$\gamma = 1$	$\gamma = 2$	$\gamma = 3$	$\gamma = 4$
C=0.1	0.895	0.85	0.845	0.87
C=1	0.71	0.75	0.815	0.775
C=5	0.705	0.835	0.73	0.815
C=10	0.725	0.835	0.79	0.755
C=50	0.715	0.79	0.77	0.755

Dari keseluruhan *trial and error* yang dilakukan, diperoleh hasil akurasi yang paling besar adalah 0.895 dengan nilai C=0.1 dan D=1. Sehingga dalam pembentukan model SVM dengan *training dataset* akan menggunakan nilai parameter C=0.1 dan D=1 sebagai parameter terbaik. Berikut adalah parameter model kernel sigmoid:

**Tabel 5. 7** Parameter Model SVM Kernel Sigmoid

Parameter	
SVM – Type	: C-Classification
SVM – Kernel	: Polynomial
Cost	: 0.1
Gamma	: 1
Number of Support Vector	: 36

Dari parameter *cost* dan *gamma* di atas, dapat dibuat *confusion matrix* untuk mendapatkan nilai akurasi dari model SVM kernel sigmoid menggunakan *testing dataset*.

**Tabel 5. 8** *Confusion Matrix* SVM Kernel Sigmoid

Prediksi	Aktual	
	Non FD	FD
Non FD	6	0
FD	1	9

Berdasarkan Tabel 5.8, diperoleh hasil bahwa terdapat dua kemungkinan status perusahaan yaitu mengalami *financial distress* atau tidak mengalami *financial distress*. Pada tabel klasifier di atas terdapat 16 prediksi yang diperoleh. Dari 16 sampel di atas, klasifier memprediksi pilihan “non FD” adalah sebanyak 6 kali dan prediksi “FD” adalah sebanyak 10 kali. Sedangkan pada data aktual terdapat 7 perusahaan *non financial distress* sedangkan 9 lainnya *financial distress*. Hasil prediksi bernilai 9 dinamakan sebagai *false positif*, dimana nilai prediksi menyatakan hasil perusahaan *non financial distress* sedangkan aktualnya perusahaan mengalami *financial distress*. Setelah diperoleh *confusion matrix*, dapat dilanjutkan dengan mencari nilai akurasi dari data *testing* menggunakan perhitungan berikut:

$$Akurasi = \frac{TP + TN}{TP + TN + FN + FP}$$

$$Akurasi = \frac{6 + 9}{6 + 0 + 1 + 9} = \frac{15}{16}$$

$$Akurasi = 0.9375$$

Diperoleh nilai akurasi klasifikasi sebesar 0.9375 atau 94%. Artinya, kemungkinan kesalahan klasifikasi perusahaan *financial distress* sebesar 6%.

### 5.5.3 Perbandingan RBF Kernel dan Sigmoid Kernel

Setelah melakukan analisis menggunakan fungsi kernel RBF dan sigmoid dari data perusahaan *financial distress* dan *non financial distress*. Selanjutnya akan ditentukan manakah fungsi kernel yang paling sesuai digunakan dalam menentukan ketepatan klasifikasi menggunakan nilai akurasi yang paling baik. Berikut adalah rangkuman nilai akurasi dari RBF kernel dan sigmoid kernel:

**Tabel 5. 9** Rangkuman Akurasi Fungsi Kernel

Fungsi Kernel	Akurasi
RBF Kernel	88%
Sigmoid Kernel	94%

Berdasarkan tabel di atas, dapat dilihat bahwa fungsi kernel yang tepat digunakan dalam menentukan ketepatan klasifikasi perusahaan *financial distress* atau

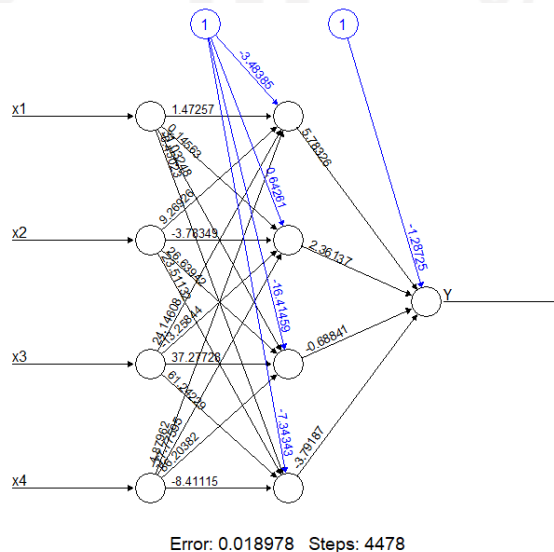
*non financial distress* adalah ketika dilakukan analisis menggunakan fungsi sigmoid kernel yang menghasilkan akurasi sebesar 94%.

## 5.6 Metode *Artificial Neural Network*

Dalam mengaplikasikan metode *Artificial Neural Network*, terdapat beberapa tahapan persiapan data yang harus dilakukan yaitu normalisasi data, lalu membagi data menjadi dua bagian yang terdiri dari data *training* dan data *testing*.

### 5.6.1 Arsitektur Jaringan Saraf Tiruan

Dalam proses ini diperoleh arsitektur jaringan saraf tiruan yang terbaik menggunakan 1 *hidden layer*, dimana jumlah *neuron input layer* sebanyak 4 fitur yaitu  $X_1, X_2, X_3,$  dan  $X_4$ . Kemudian jumlah *neuron hidden layer* sebanyak 4 yaitu  $Z_1, Z_2, Z_3,$  dan  $Z_4$  serta 1 *neuron* pada *output layer* yaitu  $Y$ . Bobot yang menghubungkan lapisan input dengan lapisan tersembunyi *neuron* pertama yaitu  $V_{.1}, V_{21}, V_{31},$  dan  $V_{41}$ , dimana  $V_{ij}$  adalah bobot *neuron input* ke- $i$  terhadap *neuron hidden* ke- $j$ . Sedangkan  $V_{01}, V_{02},$  dan  $V_{03}$  merupakan bobot bias dari lapisan *input* ke lapisan *hidden. Bobot bias lapisan *hidden* menuju lapisan *output* yaitu  $W_0$ . Berikut adalah arsitektur jaringan saraf tiruan:*



**Gambar 5. 7** Rancangan Arsitektur Jaringan

Untuk penentuan parameter-parameter yang digunakan pada penelitian ini diantaranya *learning rate* dan fungsi aktivasi. Penentuan parameter-parameter tersebut akan berpengaruh pada kinerja algoritma pada suatu jaringan yang dirancang. Besarnya *learning rate* yang digunakan pada penelitian ini adalah 0.01, sedangkan untuk fungsi aktivasi yang dipilih adalah fungsi *sigmoid biner* karena nilai *output* yang diharapkan berada pada *range* antara 0 sampai 1.

### 5.6.2 Inisialisasi Bobot

Setelah model arsitektur jaringan saraf tiruan untuk mengklasifikasi *financial distress* telah dibuat, tahap selanjutnya adalah melakukan inisialisasi bobot dan bias. Inisialisasi bobot dan bias diberikan sebelum melakukan proses pelatihan suatu sistem jaringan yang ada pada jaringan saraf tiruan. Inisialisasi bobot awal ini diberikan pada tiap-tiap *neuron* yang saling berhubungan. Faktor bobot ini mendefinisikan hubungan antar *neuron* satu dengan *neuron* lain dimana semakin besar nilai bobot suatu hubungan antara neuron tersebut maka semakin penting pula hubungan kedua *neuron* tersebut. Pemberian inisialisasi bobot awal dan bias ini dilakukan secara *random*. Berikut ini adalah bobot awal *input layer* ke *hidden layer* dan *hidden layer* ke *output layer*:

**Tabel 5. 10** Bobot Awal *Input Layer* ke *Hidden Layer*

Variabel	V[I,]	V[,j]			
		1	2	3	4
Bias	0	0.1829077	1.4032035	-0.36344033	-1.7386
X1	1	0.4173233	-1.7767756	1.31906574	0.17886
X2	2	1.0654023	0.6228674	0.04377907	1.89747
X3	3	0.970202	-0.5222834	-1.87865588	-2.2719
X4	4	-0.1016292	1.322231	-0.44706218	0.98046

**Tabel 5. 11** Bobot Awal *Hidden Layer* ke *Output*

W[j,]	W[,k]
	1
0	-1.3988256
1	1.8248724
2	1.3812987
3	-0.8388519
4	-0.2619958

### 5.6.3 Pelatihan Model *Backpropagation*

Setelah mendapatkan inisialisasi bobot dan bias, tahap selanjutnya adalah melakukan pelatihan terhadap model tersebut. Terdapat tiga fase proses pelatihan untuk *backpropagation* yaitu *feedforward*, *backpropagation*, dan perubahan bobot dan bias. Unit *input* pada penelitian ini yaitu WCTA ( $X_1$ ), RETA ( $X_2$ ), EBITA ( $X_3$ ), dan MVETL ( $X_4$ ) serta *output financial distress* ( $Y$ ). Berikut adalah data *input training*:

**Tabel 5. 12** Data *Input Training*

<b>Y</b>	<b>X<sub>1</sub></b>	<b>X<sub>2</sub></b>	<b>X<sub>3</sub></b>	<b>X<sub>4</sub></b>
0	0.799956	0.097363	0.060431	0.131495
1	0.619475	0.488643	0.053625	0.214865
1	0.799752	0.185057	0.051499	0.125696
.	.	.	.	.
.	.	.	.	.
.	.	.	.	.
1	0.500293	0.468367	0.02335	0.110925
0	0.728268	0.560681	0.084639	0.124021

#### Fase I *Feedforward*

Pada tahap ini tiap unit *input* akan menerima sinyal masukan  $x_i$  kemudian meneruskannya ke unit *hidden*. Kemudian akan dihitung semua sinyal *input* yang sudah terboboti termasuk biasnya di setiap unit *hidden*  $Z_j$  menggunakan persamaan 3.4. Berikut adalah sinyal *input* ke *hidden layer* yang telah terboboti termasuk dengan biasnya dengan menggunakan data *training* ke-1:

**Tabel 5. 13** Sinyal *Input Layer* ke *Hidden Layer*

<b>Z</b>	<b>Z<sub>in<sub>j</sub></sub></b>
1	1.340564245
2	0.983169537
3	0.175959307
4	-0.248446844

Setelah *hidden layer* menerima sinyal *input* yang telah terboboti termasuk biasnya, maka selanjutnya akan dihitung sinyal *output* di *hidden layer* dari sinyal *input* tersebut dengan fungsi aktivasi menggunakan persamaan 3.6. Berikut adalah fungsi aktivasi untuk menghitung sinyal *output* di *hidden layer*:

**Tabel 5. 14** Sinyal *Output* di *Hidden Layer*

<b>Z</b>	<b>Z<sub>j</sub></b>
Z1	0.207417284
Z2	0.272263331
Z3	0.456123323
Z4	0.56179418

Sinyal *output* di *hidden layer* akan berperan sebagai sinyal *input* di *output layer*. Sinyal *input* akan diteruskan ke *output layer* dengan bobot dan bias di *hidden layer* terhadap *output layer* pada tiap unit *output* menggunakan persamaan 3.7.

Berikut adalah hasil pada *output layer*:

**Tabel 5. 15** Sinyal *Input* dari *Hidden Layer* ke *Output Layer*

<b>Y</b>	<b>Y<sub>in<sub>k</sub></sub></b>
1	2.323072125

Setelah *output layer* menerima sinyal *input* dari *hidden layer*, maka selanjutnya sinyal *input* akan diaktifkan dengan fungsi aktivasi menggunakan persamaan 3.8. Fungsi aktivasi pada *output layer* sebagai berikut:

**Tabel 5. 16** Fungsi Aktivasi

<b>Y</b>	<b>Y<sub>k</sub></b>
1	0.089230078

Setelah berhasil diaktifkan di *output layer*, maka *output* tersebut akan disebarkan ke semua unit di *output layer*.

## **Fase II Backpropagation**

Pada tahap sebelumnya, telah didapatkan pola *output* yang dihasilkan jaringan dan akan dibandingkan dengan *output* atau target yang di-*input*-kan. Sehingga, didapatkanlah suatu eror yang akan digunakan untuk memperbaiki bobot dan bias secara mundur menggunakan persamaan 3.9. Dari persamaan tersebut, didapat hasil faktor kesalahan ( $\delta_k$ ) sebesar  $-0.007251556$ . Faktor kesalahan ( $\delta_k$ ) yang akan digunakan untuk memperbaiki bobot ( $W_{jk}$ ) dan bias ( $W_{0k}$ ) di *hidden layer* dengan *learning rate* ( $\alpha$ ) = 0.01 menggunakan persamaan 3.10. Berikut adalah hasil koreksi

bobot dan bias di *hidden layer* terhadap *output layer* setelah adanya perbaikan bobot dan bias:

**Tabel 5. 17** Koreksi Bobot dan Bias di *Hidden Layer* terhadap *Output Layer*

$\Delta W_{[j]}$	$\Delta W_{[k]}$
	<b>1</b>
0	-7.25156E-05
1	-1.5041E-05
2	-1.97433E-05
3	-3.3076E-05
4	-4.07388E-05

Menghitung penjumlahan kesalahan dari unit tersembunyi, karena jaringan hanya memiliki satu unit *output* menggunakan persamaan 3.12. Berikut adalah hasil faktor kesalahan di unit tersembunyi:

**Tabel 5. 18** Faktor Kesalahan di Unit Tersembunyi

$\delta_{in_1}$	-0.013233165
$\delta_{in_2}$	-0.010016565
$\delta_{in_3}$	0.006082982
$\delta_{in_4}$	0.001899877

*Input-an* dari faktor kesalahan di unit tersembunyi akan diaktifkan menggunakan fungsi aktivasi dengan persamaan 3.13. Berikut adalah hasil dari faktor kesalahan di unit tersembunyi:

**Tabel 5. 19** Faktor Kesalahan di Unit Tersembunyi

$\delta_j$	
$\delta_1$	-0.002175471
$\delta_2$	-0.001984642
$\delta_3$	0.001509035
$\delta_4$	0.000467715

Setelah mengetahui faktor kesalahan  $\delta_j$  yang telah diaktifkan dengan fungsi aktivasi, maka faktor kesalahan tersebut akan digunakan untuk memperbaiki bobot dan bias yang ada di lapisan bawahnya yaitu *input layer* terhadap *hidden layer* menggunakan persamaan 3.14. Berikut adalah hasil dari bobot dan bias di *input layer* terhadap *hidden layer* yang sudah dikoreksi:



**Tabel 5. 20** Koreksi Bobot dan Bias di *Input Layer* terhadap *Hidden Layer*

$\Delta V_{ij}$	
$\Delta V_{01}$	-2.17547E-05
$\Delta V_{02}$	-1.98464E-05
$\Delta V_{03}$	1.50903E-05
$\Delta V_{04}$	4.67715E-06
$\Delta V_{11}$	-1.4197E-05
$\Delta V_{12}$	-1.29517E-05
$\Delta V_{13}$	9.84788E-06
$\Delta V_{14}$	3.05228E-06
$\Delta V_{21}$	-1.61133E-05
$\Delta V_{22}$	-1.46999E-05
$\Delta V_{23}$	1.11771E-05
$\Delta V_{24}$	3.46428E-06
$\Delta V_{31}$	-2.74999E-06
$\Delta V_{32}$	-2.50876E-06
$\Delta V_{33}$	1.90755E-06
$\Delta V_{34}$	5.91233E-07
$\Delta V_{41}$	-5.66239E-06
$\Delta V_{42}$	-5.1657E-06
$\Delta V_{43}$	3.92777E-06
$\Delta V_{44}$	1.21738-E06

### Fase III Perubahan Bobot dan Bias

Tahap ini akan melakukan modifikasi bobot dan bias menggunakan koreksi bobot dan bias yang telah dilakukan di tahap sebelumnya, sehingga akan didapatkan bobot baru untuk menghasilkan target yang sesuai. Selanjutnya melakukan perhitungan pada perubahan bobot dan bias di setiap *input layer* terhadap *hidden layer* ( $V_{ij}$ ,  $V_{0j}$ ) dan *hidden layer* terhadap *output layer* ( $W_{jk}$ ,  $W_{0k}$ ). Untuk perubahan bobot dan bias pada *hidden layer* terhadap *output layer* akan dihitung menggunakan persamaan 3.16. Berikut adalah hasil dari bobot dan bias akhir pada *hidden layer* terhadap *output layer*:

**Tabel 5. 21** Bobot dan Bias Akhir pada *Hidden Layer* terhadap *Output Layer*

$W_{jk}(\text{baru})$	
$W_{10}(\text{baru})$	-1.398898116
$W_{11}(\text{baru})$	1.824857359
$W_{12}(\text{baru})$	1.381278957
$W_{13}(\text{baru})$	-0.838884976
$W_{14}(\text{baru})$	-0.262036539

Untuk perubahan bobot dan bias pada *input layer* terhadap *hidden layer* akan dihitung menggunakan persamaan 3.17. Berikut adalah hasil dari bobot dan bias akhir pada *input layer* terhadap *hidden layer*:

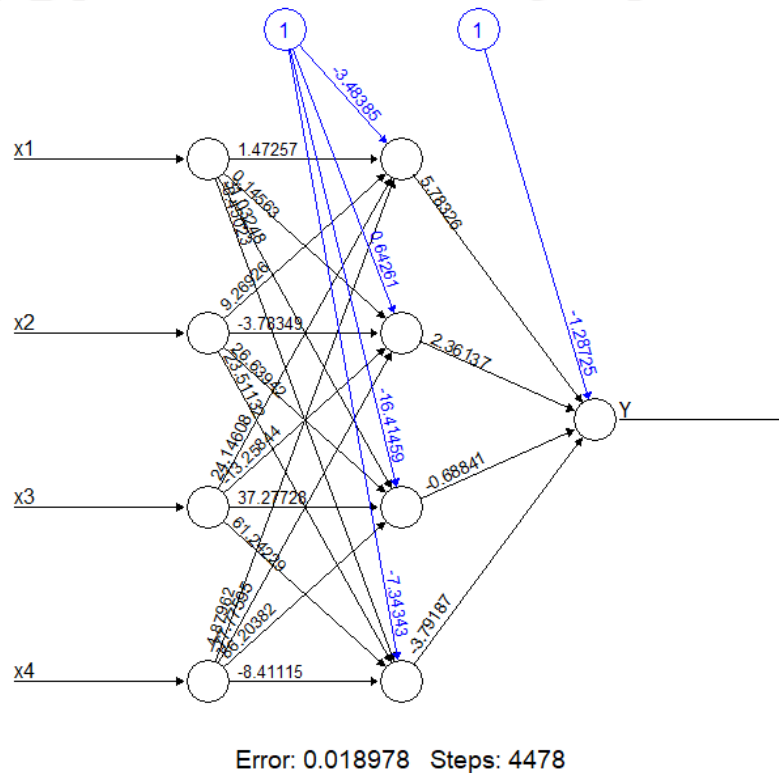
**Tabel 5. 22** Bobot dan Bias Akhir pada *Input Layer* terhadap *Hidden Layer*

$V_{ij}(\text{baru})$	
$V_{01}(\text{baru})$	0.182885945
$V_{02}(\text{baru})$	1.403183654
$V_{03}(\text{baru})$	-0.36342524
$V_{04}(\text{baru})$	-1.738593223
$V_{11}(\text{baru})$	0.417309103
$V_{12}(\text{baru})$	-1.776788552
$V_{13}(\text{baru})$	1.319075588
$V_{14}(\text{baru})$	0.178867852
$V_{21}(\text{baru})$	1.065386187
$V_{22}(\text{baru})$	0.6228527
$V_{23}(\text{baru})$	0.043790247
$V_{24}(\text{baru})$	1.897469164
$V_{31}(\text{baru})$	0.97019925
$V_{32}(\text{baru})$	-0.522285909
$V_{33}(\text{baru})$	-1.878653972
$V_{34}(\text{baru})$	-2.271924909
$V_{41}(\text{baru})$	-0.101634862
$V_{42}(\text{baru})$	1.322225834
$V_{43}(\text{baru})$	-0.447058252
$V_{44}(\text{baru})$	0.980465317

Berdasarkan pelatihan jaringan yang telah dilakukan dengan rancangan arsitektur jaringan yang terdiri dari 3 lapisan yang masing-masing memiliki 4 *neuron*

pada *input layer*, 4 *neuron* pada *hidden layer*, dan 1 *neuron* pada *output layer*. Berikut adalah plot arsitektur jaringan saraf tiruan klasifikasi perusahaan *financial distress* dan *non financial distress* yang telah dirancang.

Arsitektur jaringan saraf tiruan pada Gambar 5.10 menunjukkan hasil klasifikasi menggunakan algoritma *backpropagation*, dengan kesalahan optimum (*error*) untuk kasus ini adalah 0.018978 untuk 4478 langkah atau iterasi. Artinya, jaringan tersebut telah melakukan sebanyak 3891 kali iterasi sehingga menghasilkan bobot seperti pada plot.



**Gambar 5. 8** Arsitektur Jaringan Saraf Tiruan Klasifikasi Perusahaan *Financial Distress*

#### 5.6.4 Pengujian *Backpropagation*

Proses pelatihan *backpropagation* yang sudah dilakukan menghasilkan bobot yang akan digunakan pada tahap pengujian ini. Hasil jaringan yang didapat akan diterapkan pada data *testing* untuk mengetahui validasi dari hasil klasifikasi yang didapatkan. Pengujian ini menggunakan data *testing* dengan pembagian presentase

data sebesar 25% dari jumlah data yang digunakan. Berikut adalah hasil uji *backpropagation* untuk mengklasifikasi perusahaan *financial distress* dan *non financial distress*.

**Tabel 5. 23 Confusion Matrix ANN**

Prediksi	Aktual	
	Non FD	FD
Non FD	5	2
FD	2	7

Berdasarkan Tabel 5.22, diperoleh hasil bahwa terdapat dua kemungkinan status perusahaan yaitu *financial distress* atau *non* mengalami *financial distress*. Pada tabel klasifier di atas terdapat 16 prediksi yang diperoleh. Dari 16 sampel di atas, klasifier memprediksi pilihan “non FD” adalah sebanyak 7 kali dan prediksi “FD” adalah sebanyak 9 kali. Sedangkan pada data aktual terdapat 9 perusahaan *non financial distress* sedangkan 9 lainnya *financial distress*. Hasil prediksi bernilai 9 dinamakan sebagai *false positif*, dimana nilai prediksi menyatakan hasil perusahaan *non financial distress* sedangkan aktualnya perusahaan mengalami *financial distress*. Setelah diperoleh *confusion matrix*, dapat dilanjutkan dengan mencari nilai akurasi dari data *testing* menggunakan perhitungan berikut:

$$Akurasi = \frac{TP + TN}{TP + TN + FN + FP}$$

$$Akurasi = \frac{5 + 7}{5 + 2 + 2 + 7} = \frac{12}{16}$$

$$Akurasi = 0.75$$

Diperoleh nilai akurasi klasifikasi sebesar 0.75 atau 75%. Artinya, kemungkinan kesalahan klasifikasi perusahaan *financial distress* sebesar 25%.

### 5.7 Perbandingan Metode SVM dan ANN

Untuk menentukan metode terbaik dari kedua metode yaitu SVM dan ANN dalam klasifikasi perusahaan *financial distress* dan *non financial distress* adalah dengan melakukan perbandingan tingkat keakuratan metode. Dengan menggunakan *confusion matrix* yang telah dilakukan sebelumnya, didapatkan hasil sebagai berikut:

**Tabel 5. 24** Hasil Perbandingan Metode

<b>Metode</b>	<b>Akurasi</b>
<i>Support Vector Machine (SVM)</i>	94%
<i>Artificial Neural Network (ANN)</i>	75%

Dari hasil perbandingan nilai akurasi pada kedua metode dapat dilihat bahwa dalam melakukan klasifikasi perusahaan *financial distress* dan *non financial distress* lebih baik menggunakan metode SVM daripada ANN karena nilai akurasi yang lebih tinggi yaitu sebesar 94%.



## **BAB VI PENUTUP**

### **6.1 Kesimpulan**

Berdasarkan dari rumusan masalah dan hasil penelitian yang sudah dijelaskan dalam bab pembahasan, maka dapat disimpulkan sebagai berikut:

1. Gambaran umum rasio keuangan perusahaan sektor pertambangan tahun 2018 menunjukkan bahwa perusahaan yang tidak mengalami *financial distress* sebanyak 32 perusahaan dan yang mengalami *financial distress* sebanyak 6 perusahaan dari 38 perusahaan.
2. Klasifikasi menggunakan metode SVM dibagi menjadi 2, yaitu SVM RBF kernel dan SVM Sigmoid kernel. Akurasi SVM RBF kernel dengan parameter optimum  $C=5$  dan  $\gamma=2$  adalah 88%. Akurasi SVM sigmoid kernel dengan parameter optimum  $C=0.1$  dan  $D=1$  adalah 94%. Untuk tingkat akurasi pada metode ANN adalah sebesar 75%.
3. Penelitian ini menghasilkan metode terbaik untuk melakukan analisis klasifikasi perusahaan *financial distress* perusahaan sektor pertambangan tahun 2017-2018 adalah metode *Support Vector Machine* menggunakan sigmoid kernel yaitu sebesar 94%, yang berarti ketepatan metode klasifikasi SVM untuk data ini sudah sangat bagus.

### **6.2 Saran**

Adapun saran yang dapat diberikan dalam penelitian ini, yaitu:

1. Penelitian selanjutnya dapat menggunakan metode-metode analisis *financial distress* lain seperti *trait recognition*, *fuzzy logit*, dan *decision tree*.
2. Penelitian selanjutnya dapat menambahkan variabel rasio keuangan lebih banyak lagi yang kemungkinan berpengaruh terhadap *financial distress* dan dapat mengembangkan sampel penelitian tidak hanya sektor pertambangan saja.

## DAFTAR PUSTAKA

- Afriyeni, E. (2013). Model Prediksi Financial Distress Perusahaan. *Poli Bisnis*, Vol.4 No.2.
- Agustina, Y., & Rahmawati. (2010). Kebangkrutan Perusahaan Menggunakan Model Altman dan Zavgren pada Perusahaan Food and Beverages. *The Winners*, Vol. 11 No. 1.
- Alifia, N., & Rikumahu, B. (2020). Prediksi Financial Distress Perusahaan Pertambangan Batubara di Bursa Efek Indonesia Menggunakan Support Vector Machine, K-Nearest Neighbor, dan Naive Bayes Classifier. *Jurnal Mitra Manajemen*, Vol.4 No.6.
- Altman, E. I. (1968). Financial Ratios, Discriminant Analysis and The Prediction of Corporate Bankruptcy. *The Journal of Finance*, Vol.23 No.4.
- Amalia, H. (2018). Perbandingan Metode Data Mining SVM dan NN untuk Klasifikasi Penyakit Ginjal Kronis. *Jurnal PILAR Nusa Mandiri*, Vol.14 No.1.
- Amalina, N. (2016). *Penerapan Metode Artificial Neural Network untuk Meramalkan nilai Ekspor Migas dan Non Migas di Indonesia*. Surabaya: Thesis.
- Andhito, I. (2011). *Analisis Rasio Keuangan dalam Memprediksi Kondisi Financial Distress Perusahaan*. Jakarta: Tugas Akhir.
- Anggraeni. (2019). Analisa Kinerja Keuangan Perusahaan Pertambangan yang Terdaftar dalam Bursa Efek Indonesia. *Journal eCo-Buss*, Vol.1 No.3.
- Aprylia, C. (2016). *Analisis Potensi Financial Distress dengan Metode Altman Z-Score pada Bank Umum Syariah di Indonesia Periode Tahun 2010-2014*. Jakarta: Tugas Akhir.
- Assaffat. (2015). Analisis Akurasi Support Vector Machine dengan Fungsi Kernel Gaussian RBF untuk Prakiraan Beban Listrik Harian Sektor Industri. *Jurnal Momentum*, Vol.11 No.2.
- Awad, M., & Khanna, R. (2015). *Efficient Learning Machines : Tehories, Concepts, Applications for Engineers and System Designers*. United States: Apress.

- Brigham, E., & Houston, J. (2006). *Dasar-Dasar Manajemen Keuangan*. Jakarta: Salemba Empat.
- Campbell, C., & Ying, Y. (2011). Learning with Support Vector Machine. *Morgan Clay*, Vol.5 No.1.
- Chamidah, N., Wiharto, & Salamah, U. (2012). Pengaruh Normalisasi Data pada Jaringan Syaraf Tiruan Backpropagasi Gradient Descent Adaptive Gain (BPGDAG) untuk Klasifikasi. *Itsmart*, Vol1. No.1.
- Curry, K., & Banjarnahon, E. (2018). Financial Distress pada Perusahaan Sektor Properti Go Public di Indonesia. *Seminar Nasional Pakar ke-1*, Vol.2.
- Dewi, I. R., Handayani, S. R., & Nuzula, N. F. (2014). Pengaruh Struktur Modal terhadap Nilai Perusahaan. *Jurnal Administrasi Bisnis*, Vol.17 No.1.
- Dwijayanti, P. F. (2010). Penyebab, Dampak, dan Prediksi dari Financial Distress serta Solusi untuk Mengatasi Financial Distress. *Akuntansi Kontemporer*, Vol.2 No.2.
- Effendi, A. (2013). *Penggunaan Artificial Neural Network untuk Mendeteksi Kelainan Mata Miopi pada Manusia dengan Metode Backpropagation*. Malang: Tugas Akhir.
- Endri. (2009). *Prediksi Kebangkrutan Bank untuk Menghadapi dan Mengelola Perubahan Lingkungan Bisnis: Analisis Model Altman Z-Score*. Surabaya: ABFI Institute Perbarnas.
- Gamayuni, R. R. (2009). Berbagai Alternatif Model Prediksi Kebangkrutan. *Akuntansi dan Keuangan*, Vol. 14 No. 1.
- Goenawan, Sastranegara, B. S., & Rizal, S. (2012). Pengaruh Kualitas Laporan Keuangan dalam Hubungannya dengan Pengukuran Kinerja. *Jurnal Akuntansi & Keuangan*, Vol.3 No.1.
- Hadi, S., & Anggraeni, A. (2008). Pemilihan Prediktor Delisting Terbaik (Perbandingan antara The Zmijewski Model, The Altman Model, dan The Springate Modal). *Jurnal AKuntansi dan Auditing Indonesia*, Vol.12 No.2.



- Hanafi, M., & Halim, A. (2009). *Analisis Laporan Keuangan*. Yogyakarta: Unit Penerbit dan Percetakan.
- Herlina. (2016). Cross Entropy untuk Optimasi Lagrange Multipliers pada Support Vector Machines sebagai Model Prediksi Financial Distress. *Jurnal Teknik Industri Heuristic*, Vol.13 No.2.
- Hermawan, A. (2006). *Pengantar Jaringan Syaraf Tiruan, Teori, dan Aplikasi*. Yogyakarta: Andi.
- Hery. (2017). *Riset Akuntansi*. Jakarta: Gramedia Widiasarana.
- Hilmiyah, F. (2017). *Prediksi Kinerja Mahasiswa Menggunakan Support Vector Machine untuk Pengelola Program Studi di Perguruan Tinggi (Studi Kasus: Program Studi Magister Statistika ITS)*. Surabaya: Tesis.
- Horak, J., Vrbka, J., & Suler, P. (2020). Support Vector Machine Methods and Artificial Neural Networks Used for the Development of Bankruptcy Prediction Models and their Comparison. *Journal of Risk and Financial Management*, Vol.13 No.60.
- Kariyoto. (2018). *Manajemen Keuangan : Konsep dan Implementasi*. Malang: UB Press.
- Kasmir. (2009). *Analisis Laporan Keuangan*. Jakarta: Raja Pres.
- Kordestani, G., Biglari, V., & Bakhtiari, M. (2011). Ability of Combinations of Cash Flow Components to Predict Financial Distress. *Verslas: Teorija ir Praktika*, Vol.12 No.3.
- Kristanto, A. (2004). *Jaringan Saraf Tiruan (Konsep Dasar, Algoritma dan Aplikasinya)*. Yogyakarta: Gaya Media.
- Kurniawansyah, A. S. (2018). Implementasi Metode Artificial Neural Network dalam Memprediksi Hasil Ujian Kompetensi Kebidanan (Studi Kasus : Akademi Kebidanan Dehasen Bengkulu). *Jurnal Pseudocode*, Vol.5 No.1.
- Kusumadewi, S. (2003). *Artificial Intelligence*. Yogyakarta: Graha Ilmu.

- Lee, M. C., & To, C. (2010). Comparison of Support Vector Machine and Back Propagation Neural Network in Evaluating the Enterprise Financial Distress. *International Journal of Artificial Intelligence&Applications*, Vol.1 No.3.
- Lesmana, R., & Surjanto, R. (2004). *Financial Performance Analyzing*. Jakarta: Gramedia.
- Lesnussa, Y. A., Sinay, L. J., & Idah, M. R. (2017). Aplikasi Jaringan Saraf Tiruan Backpropagation untuk Penyebaran Penyakit Demam Berdarah Dengue (DBD) di Kota Ambon. *Matematika Integratif*, Vol.13 No.2.
- Lesnussa, Y., Latuconsina, S., & Persulesy, E. (2015). Aplikasi Jaringan Saraf Tiruan Backpropagation untuk Memprediksi Prestasi Siswa SMA (Studi Kasus: Prediksi Prestasi Siswa SMAN 4 Ambon). *Matematika Integratif*, Vol.11 No.2.
- Liana, D., & Sutrisno. (2014). Analisis Rasio Keuangan untuk Memprediksi Kondisi Financial Distress Perusahaan Manufaktur. *Jurnal Studi Manajemen dan Bisnis*, Vol.1 No.2.
- Limanto, M. C. (2016). Analisis Prediksi Kebangkrutan Perusahaan Sektor Pertambangan dan Pertanian Menggunakan Metode Grover Tahun 2012-2015. *Poli Bisnis*, Vol.2 No.2.
- Marhamah, S., Maiyastri, & Asdi, Y. (2011). Studi Prestasi Mahasiswa dengan Analisis Statistika Deskriptif (Studi Kasus: Mahasiswa Program Studi Matematika FMIPA Universitas Andalas Tahun 2009-2011). *Jurnal Matematika UNAND*, Vol.5 No.4.
- Matsumaru, M., Kawanaka, T., Kaneko, S., & Katagiri, H. (2019). Bankruptcy Prediction for Japanese Corporations using Support Vector Machine, Artificial Neural Network, and Multivariate Discriminant Analysis. *International Journal of Industrial Engineering and Operations Management*, Vol.1 No.1.
- McLeod, R. (2002). *Introduction to Information System: A Problem Solving Approach*. United States: Pergamun Press.

- Mustakim, J., Ratianingsih, R., & Lusiyanti, D. (2017). Prediksi Kualitas Air Bersih Kota Palu Menggunakan Metode Backpropagation. *Jurnal Ilmiah Matematika dan Terapan*, Vol. 14 No. 1.
- Nasution, L. M. (2017). Statistika Deskriptif. *Jurnal Hikmah*, Vol. 14 No. 1.
- Nindita, K. (2014). Prediction on Financial Distress of Mining Companies Listed in BEI using Financial Variables and Non-Financial Variables. *European Journal of Business and Management*, Vol.6 No.34.
- Ningrum, H. (2018). *Perbandingan Metode Support Vector Machine (SVM) Linear, Radial Basis Function (RBF), dan Polinomial Kernel dalam Klasifikasi Bidang Studi Lanjut Pilihan Alumni UII*. Yogyakarta: Tugas Akhir.
- Nirmalasari, L. (2018). *Analisis Financial Distress pada Perusahaan Sektor Property, Real Estate dan Konstruksi Bangunan yang Terdaftar di Bursa Efek Indonesia*. Yogyakarta: Tugas Akhir.
- Nugroho, A. (2007). *Pengantar Support Vector Machine*. Nagoya Jepang: Intitute of Technology.
- Ondang, R. C. (2013). *Analisis Financial Distress dengan Menggunakan Metode Altman Z-Score untuk Memprediksi Kebangkrutan pada Perusahaan*. Bandung: Tugas Akhir.
- Platt, H., & Platt, M. (2002). Predicting Financial Distress. *Journal of Financial Service PProfessional*s, Vol. 56.
- Pratama, J. (2016). *Prediksi Financial Distress pada Perusahaan Manufaktur di Indonesia*. Yogyakarta: Tugas Akhir.
- Puspitaningrum, D. (2006). *Pengantar Jaringan Saraf Tiruan*. Yogyakarta: Andi Offset.
- Rahman, M., Darmawidjadja, M., & Alamsah, D. (2017). Klasifikasi untuk Diagnosa Diabetes Menggunakan Metode Bayesian Regularization Neural Network. *Jurnal Informatika*, Vol.11 No.1.

- Ramadhan, K. D., & Syarfah, L. (2016). Analisis Laporan Keuangan dalam Mengukur Kinerja Perusahaan pada PT. Ricky Kurniawan Kertapersada (Makin Group) Jambi. *Valuta*, Vol.2 No.2.
- Ramadhani, A., & Lukviarman, N. (2009). Perbandingan Analisis Prediksi Kebangkrutan Menggunakan Model Altman Pertama, Altman Revisi, dan Altman Modifikasi dengan Ukuran dan Umur Perusahaan sebagai Variabel Penjelas (Studi pada Perusahaan Manufaktur yang Terdaftar di Bursa Efek Indonesia). *Jurnal Siasat Bisnis*, Vol. 12 No.1.
- Riswan, & Kesuma, Y. F. (2014). Analisis Laporan Keuangan sebagai Dasar dalam Penilaian Kinerja Keuangan PT. Budi Satria Wahana Motor. *Jurnal Akuntansi dan Keuangan*, Vol.5 No.1.
- Rizki, N. D. (2019). *Pengaruh Rasio Keuangan terhadap Probabilitas Terjadinya Financial Distress pada Perusahaan Keluarga yang Terdaftar di Bursa Efek Indonesia*. Yogyakarta: Tugas Akhir.
- Rodoni, A., & Muslih, R. (2008). Prediksi Kondisi Financial Distress Perusahaan Go-Public Menggunakan Analisis Multinomial Logit. *Etikonomi*, Vol.8 No.2.
- Ross, S. A., Westerfield, R. W., & Jordan, B. D. (2006). *Fundamentals of Corporate Finance*. New York: McGraw-Hill Irwin.
- Rudianto. (2013). *Akuntansi Manajemen*. Jakarta: Penerbit Erlangga.
- Salehi, M., Shiri, M., & Pasikhani, M. (2016). Predicting Corporate Financial Distress using Data Mining Techniques an Application in Tehran Stock Exchange. *International Journal of Law and Management*, Vol.58 No.2.
- Sanjaya, S., & Rizky, M. F. (2018). Analisis Profitabilitas dalam Menilai Kinerja Keuangan pada PT. Taspen (Persero) Medan. *Kitabah*, Vol. 2 No. 2.
- Santosa, B. (2007). *Data Mining Teknik Pemanfaatan Data untuk Keperluan Bisnis*. Yogyakarta: Graha Ilmu.
- Santosa, B. (2009). *Application of the Cross-Entropy Method to Dual Lagrange Support Vector Machine*. Springer: Lectures Notes in Artificial.

- Shintia, N. (2017). Analisis Rasio Solvabilitas untuk Menilai Kinerja Keuangan terhadap Asset dan Equity pada PT. Bank Rakyat Indonesia (Persero) Tbk Periode 2012-2015. *At-Tadbir*, Vol.1 No.1.
- Simanjuntak, C. F., & Wiwin, A. (2017). Pengaruh Rasio Keuangan terhadap Financial Distress. *E-Proceeding of Management*, 1580-1586.
- Supriyadi. (2018). *Analisis Klasifikasi Genre Musik Pop dan Klasik pada Layanan Streaming Musik Spotify Menggunakan Artificial Neural Network (ANN) (Studi Kasus : Lagu dengan Genre Musik Pop dan Klasik di Layanan Streaming Musik Spotify)*. Yogyakarta: Tugas Akhir.
- Tamari, M. (1996). Financial Ratios as A Means of Forecasting Bankruptcy. *Management Internatioan Review*, Vol. 4.
- Usman, H., & Akbar, P. S. (2003). *Pengantar Statistika*. Jakarta: PT. Bumi Aksara.
- Widarjo, W., & Setiawan, D. (2009). Pengaruh Rasio Keuangan terhadap Kondisi Financial Distress Perusahaan Otomotif. *Jurnal Bisnis dan Akuntansi*, Vol.11 No.2.
- Yahya, S. (2018). *Klasifikasi Ketepatan Lama Studi Mahasiswa Menggunakan Metode Support Vector Machine dan Random Forest*. Yogyakarta: Tugas Akhir.
- Yuanita, I. (2010). Prediksi Financial Distress dalam Industri Textile dan Garmet. *Jurnal Akuntansi dan Manajemen*, Vol.5 No.1.

## LAMPIRAN

### Lampiran 1 Data Penelitian

Y	x1	x2	x3	x4
0	0.111015	0.306097	0.116276	1.560041
0	0.089673	0.044375	0.037996	1.454927
1	-0.4999	-0.37686	-0.08218	0.029356
0	0.165092	-0.03445	0.017008	1.993505
0	-0.16286	-0.19044	0.021087	0.44863
0	-0.07425	-0.17081	0.507394	0.55169
0	0.065299	0.302131	0.380885	1.584893
0	-0.17869	-0.69003	0.042703	0.147984
0	0.081884	0.465278	0.605399	1.434178
0	-0.22364	0.303169	0.221806	0.847826
0	0.284872	-0.55909	0.012695	0.802659
1	-0.06867	-0.06013	-0.04552	0.681688
0	0.137579	0.058511	0.091126	0.283455
0	0.520884	0.361153	0.062186	1.400094
0	0.059616	0.099928	0.056368	0.538825
1	0.07194	-0.03286	0.002011	1.292942
0	0.113194	0.134806	0.193326	0.819796
0	0.032207	0.250531	0.03957	4.409549
0	0.518405	0.375767	0.102976	4.886479
0	0.206887	0.654848	0.037511	5.910195
0	0.261001	0.407205	0.254631	2.05052
0	0.080456	0.094141	0.00955	2.837403
0	0.385967	0.56396	1.487748	2.517459
0	-0.03551	0.101778	0.108761	0.510996
0	0.138058	0.13338	0.037856	0.358917
0	0.250728	0.346204	0.074243	1.039857
0	0.483165	0.465029	0.273895	3.052832
1	0.284631	-0.44115	-0.00133	0.768557
0	-0.05439	0.176558	0.031818	0.6768
0	0.281457	0.017955	0.281267	2.058612
0	0.184164	0.29073	0.062132	0.524441
0	0.051405	0.286739	0.045013	0.694638
0	-0.14193	0.066446	0.101668	1.429587

1	0.150259	-0.28922	-0.04357	1.008472
1	-0.65891	-0.13098	-0.06349	0.255643
0	0.200294	0.064019	0.0507	0.758705
0	0.051772	0.186524	0.193833	0.753247
0	0.048347	0.038667	0.109037	0.806543



## Lampiran 2 Syntax Program R Metode Support Vector Machine

```
library(ROSE)

datab2=read.csv("E:\\SKRIPSI BISMILLAH\\data\\cobs27.csv", sep=";")
datab2$x1=(datab2$x1-min(datab2$x1))/(max(datab2$x1)-min(datab2$x1))
datab2$x2=(datab2$x2-min(datab2$x2))/(max(datab2$x2)-min(datab2$x2))
datab2$x3=(datab2$x3-min(datab2$x3))/(max(datab2$x3)-min(datab2$x3))
datab2$x4=(datab2$x4-min(datab2$x4))/(max(datab2$x4)-min(datab2$x4))

table(datab2$Y)
prop.table(table(datab2$Y))
#balancing data menggunakan over sampling
over <- ovun.sample(Y~., data=datab2, method="over",
                    N=64, seed=30)$data
write.csv(under, "E:/oversampling.csv")
table(over$Y)
str(over)

##training testing
nrow(over)
s <- round(nrow(over)*0.75)
s
set.seed(100)
samp=sample(1:nrow(over),s)
head(samp)

## Memisahkan data
trainingb = over[samp,]
dim(trainingb)
testingb = over[-samp,]
dim(testingb)

library(caret)
library(e1071)
###SVM###
#1. tuning kernel RBF
tune.SVMR10b<-tune(svm,factor(Y)~., data=trainingb, kernel="radial",
                 ranges=list(cost=c(0.1,1,5,10,50),
                             gamma=c(1,2,3,4),
                             tunecontrol=tune.control(sampling="cross")))
summary(tune.SVMR10b)
#SVM kernel RBF OPTIMAL DI K=, C=5, GAMMA=2
svmR= svm(factor(Y)~., data=trainingb, cost=5, gamma=2,
          kernel="radial")
summary(svmR)
#prediksi dan akurasi kernel RBF
pred.rbf<-predict(svmR,testingb)
```



```

confusionMatrix(factor(pred.rbf), factor(testingb$Y))

#2. tuning kernel SIGMOID
tune.svmS=tune(svm,factor(Y)~., data=trainingb, kernel="sigmoid",
              types="C-classification",
ranges=list(cost=c(0.1,1,5,10,50), gamma=c(1,2,3,4)),
              tunecontrol=tune.control(sampling="cross"))
summary(tune.svmS)
#optimal
svmS=svm(factor(Y)~., data=trainingb, cost=0.1, gamma=1,
kernel="sigmoid")
summary(svmS)
#prediksi dan akurasi kernel LINEAR
pred.sig<-predict(svmS, testingb)
confusionMatrix(factor(pred.sig), factor(testingb$Y))

```



### Lampiran 3 Syntax Program R Metode *Artificial Neural Network*

```
###ANN###
library(ROSE)

datab=read.csv("E:\\SKRIPSI BISMILLAH\\data\\cobs27.csv", sep=";")
datab$x1=(datab$x1-min(datab$x1))/(max(datab$x1)-min(datab$x1))
datab$x2=(datab$x2-min(datab$x2))/(max(datab$x2)-min(datab$x2))
datab$x3=(datab$x3-min(datab$x3))/(max(datab$x3)-min(datab$x3))
datab$x4=(datab$x4-min(datab$x4))/(max(datab$x4)-min(datab$x4))

table(datab$Y)
prop.table(table(datab$Y))

#balancing data menggunakan over sampling
over <- ovun.sample(Y~., data=datab, method="over",
  N=64, seed=30)$data
#write.csv(under,"E:/oversampling.csv")
table(over$Y)
str(over)

##training testing
nrow(over)
s <- round(nrow(over)*0.75)
s
set.seed(100)
samp=sample(1:nrow(over),s)
head(samp)

## Memisahkan Data
train = over[samp,]
dim(train)
test = over[-samp,]
dim(test)

# Mengambil nama variabel, variabel independennya saja
feats <- names(over[,2:5])
feats

#membuat formula ANN untuk memudahkan pengujian data train
# Concatenate strings
f <- paste(feats,collapse='+')
f
f <- paste('Y ~',f)
f

# Convert to Formula
f <- as.formula(f)
```

```
f

## Train Neural Net
library(neuralnet)
nn <- neuralnet(f, train,
               hidden=c(4),
               linear.output = T)

nn

# Plot Model
plot(nn)

# Prediksi Model
pred1 <- compute(nn, test[2:5])
pred1.r <- ifelse(pred1$net.result>0.5,1,0)

# Confussion Matrix
library(caret)
confusionMatrix(as.factor(pred1.r), as.factor(test$Y))
```

