

Financial Distress Classification Using Feedforward Neural Network Based on Altman and Ohlson Financial Ratios

Klasifikasi *Financial Distress* Menggunakan *Feedforward Neural Network* Berdasarkan Rasio Keuangan Altman dan Ohlson

Annisa Salsabila Pratiwi^{1*}, Galuh Oktavia Siswono^{2*}, Prilyandari Dina Saputri^{3*}

Departemen Aktuaria, Institut Teknologi Sepuluh Nopember, Surabaya

Email: nisalsabila09@gmail.com¹, galuhoktaviast@gmail.com², prilyandaridina@its.ac.id³

Abstract

The ever-changing economy requires companies to anticipate future conditions in order to avoid financial distress, a continuous decline in financial conditions. The research focused on comparing Altman and Ohlson's financial ratio in classifying financial distress on Property and Real Estate companies using the Feedforward Neural Network. The data used is the financial report data of 19 Property and Real Estate companies listed on the Indonesian Stock Exchange in 2016-2022, with the initial status of financial conditions based on earnings per share. (EPS). The study also used the Synthetic Minority Oversampling Technique (SMOTE) method to address class imbalances. The best financial ratio is selected based on accuracy values and Area Under Curve (AUC). Altman's financial ratio with the FFNN model architecture (5-2-1) with a balance of 60:40 yields an accuracy of 84.62% and an AUC of 0.8325. The Ohlson Financial ratio with the 60:40 data balancing process and the FFNN model architecture (9-4-1) yields an accuracy of 93.27% and an AUC of 0.9045. Thus, in predicting financial distress in companies in the Property and Real Estate sector, Ohlson's financial ratio with the predictor variables Corporate Size (SIZE), Total Liabilities to Total Assets (TLTA), Working Capital to Total Assets (WCTA), Current Liability to Current Asset (CLCA), OENEG, Net Income to total assets (NITA), Cash Flows Operating to Total Responsibilities (CFOTL), Net Revenue (INTWO), and Net Incoming Change (CHIN) yielded the best results. This best ratio can be used as a consideration in using alternative financial ratio to classify financial distress.

Keywords: Area Under Curve, Feedforward Neural Network, Financial Distress, Financial Ratio



JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

Annisa Salsabila Pratiwi, Galuh Oktavia Siswono, Prilyandari Dina Saputri

Abstrak

Kondisi perekonomian yang selalu berubah menuntut perusahaan untuk mengantisipasi kondisi mendatang demi menghindari *financial distress*, penurunan kondisi keuangan yang berkelanjutan dan terjadi sebelum kebangkrutan. Fokus pada penelitian ini membandingkan rasio keuangan Altman dan Ohlson dalam mengklasifikasikan *financial distress* pada perusahaan Properti dan Real Estate menggunakan *Feedforward Neural Network*. Data yang digunakan merupakan data laporan keuangan 19 perusahaan Properti dan Real Estate yang terdaftar di Bursa Efek Indonesia tahun 2016-2022, dengan status awal kondisi keuangan berdasarkan *Earnings Per Share* (EPS). Penelitian ini juga menggunakan metode *Synthetic Minority Oversampling Technique* (SMOTE) untuk mengatasi ketidakseimbangan kelas. Rasio terbaik dipilih berdasarkan nilai akurasi dan *Area Under Curve* (AUC). Rasio keuangan Altman dengan arsitektur model FFNN (5-2-1) dengan balancing 60:40 menghasilkan nilai akurasi 84,62% dan AUC 0,8325. Rasio Keuangan Ohlson dengan proses *balancing* data 60:40 dan arsitektur model FFNN (9-4-1) menghasilkan nilai akurasi 93,27% dan AUC 0,9045. Dengan demikian, dalam memprediksi *financial distress* pada perusahaan sektor Properti dan Real Estate, rasio keuangan Ohlson dengan variabel prediktor Ukuran Perusahaan (SIZE), *Total Liabilities to Total Assets* (TLTA), *Working Capital to Total Assets* (WCTA), *Current Liabilities to Current Assets* (CLCA), Perbandingan Total Liabilities dan Total Assets (OENEG), *Net Income to Total Assets* (NITA), *Cash Flows Operating to Total Liabilities* (CFOTL), Nilai *Net Income* (INTWO), dan Perubahan *Net Income* (CHIN) memberikan hasil terbaik. Hasil klasifikasi ini dapat digunakan sebagai pertimbangan dalam menggunakan alternatif rasio keuangan untuk mengklasifikasikan *financial distress*.

Kata kunci: *Area Under Curve*, *Feedforward Neural Network*, *Financial Distress*,
Rasio Keuangan

1. PENDAHULUAN

1.1 Latar Belakang

Bank Dunia memprediksi mengenai kemungkinan resesi ekonomi global pada tahun 2023 [5]. Beberapa indikasi sudah mulai terasa, salah satunya peningkatan suku bunga acuan di beberapa negara untuk meredam tingkat inflasi. Presiden Jokowi mulai mengkhawatirkan dampak ketidakpastian ekonomi global tersebut terhadap Indonesia, karena akan sangat mempengaruhi kondisi perekonomian negara. Untuk menghadapi situasi ekonomi yang terus mengalami perubahan, perusahaan harus melakukan pengelolaan keuangan dengan sebaik mungkin untuk menghindari terjadinya *financial distress*. *Financial distress* adalah kondisi dimana terjadi penurunan kondisi keuangan secara terus menerus sebelum terjadi kebangkrutan [12].

Beberapa perusahaan, termasuk Properti dan *Real Estate*, menghadapi risiko kebangkrutan. Maka dari itu, model prediksi *financial distress* diperlukan untuk memprediksi kondisi keuangan perusahaan sebagai bentuk antisipasi dan peringatan dini. Altman dan Ohlson merupakan contoh dari model prediksi *financial distress* yang masih digunakan hingga saat ini. Altman dan Ohlson menggunakan berbagai rasio keuangan yang signifikan berpengaruh terhadap *financial distress*. Penelitian lain mencari metode terbaik dalam memprediksi *financial distress*. Berdasarkan penelitian sebelumnya didapat bahwa metode *Neural Network* terbukti memiliki akurasi yang lebih baik dibandingkan metode lain seperti *Support Vector Machine*, Logistik Biner, dan Analisis Diskriminan [17] [18]. Maka dari itu, penelitian ini berfokus pada perbandingan rasio keuangan Altman dan Ohlson dalam mengklasifikasikan *financial distress* menggunakan metode *Feedforward Neural Network* (FFNN). Metode tersebut dipilih karena merupakan jenis *Neural Network* yang paling sederhana dan paling umum digunakan. Bahkan ketika diterapkan pada sektor keuangan, metode FFNN lebih baik daripada metode klasik [16]. Status awal kondisi keuangan perusahaan ditentukan berdasarkan *Earnings per Share*.

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

Annisa Salsabila Pratiwi, Galuh Oktavia Siswono, Prilyandari Dina Saputri

Penelitian ini melibatkan 19 perusahaan sektor Properti dan *Real Estate* yang terdaftar di Bursa Efek Indonesia (BEI) periode 2016-2022. Untuk mencari rasio keuangan yang terbaik, dilakukan evaluasi performa model berdasarkan nilai akurasi dan *Area Under Curve* (AUC) terbesar. Sebagai perbandingan, dilakukan metode SMOTE pada data *training*, yang bertujuan untuk menghindari pembentukan model yang berfokus pada kelas mayoritas. Hasil dari penelitian ini diharapkan dapat memberikan alternatif rasio keuangan yang lebih baik dalam mengklasifikasikan kondisi *financial distress*, khususnya perusahaan di sektor Properti dan *Real Estate* di Indonesia

1.2 Studi Literatur

A. *Financial Distress*

Financial distress merupakan tahapan penurunan kondisi keuangan yang terjadi sebelum mengalami kebangkrutan [12]. *Financial distress* juga dapat didefinisikan sebagai kondisi dimana aset perusahaan tidak dapat memenuhi kewajiban yang harus dilunasi, sehingga memaksa perusahaan mengambil tindakan dengan segera [4]. Penyebab *financial distress* terbagi menjadi tiga, yaitu: perusahaan atau manajemen tidak dapat mengalokasikan sumber daya yang ada di perusahaan secara tepat, jika pencampuran aset sudah benar tetapi struktur keuangan salah dengan *liquidity constraints*, perusahaan memiliki campuran aset dan struktur keuangan yang benar tetapi dikelola dengan buruk atau salah [2]. Terdapat beberapa indikator suatu perusahaan mengalami *financial distress* [12], salah satunya adalah mengalami *Earnings per Share* negatif.

B. Model Prediksi *Financial Distress*

1. Model Altman

Model Altman dikembangkan pada tahun 1968, berdasarkan laporan keuangan satu sampai lima tahun sebelum perusahaan dinyatakan bangkrut, menggunakan *Multiple Discriminant Analysis* [1]. Model Altman menghasilkan lima rasio keuangan yang signifikan mempengaruhi *financial distress*, yaitu *Working Capital to Total Assets* (WCTA), *Retained Earnings to Total Assets* (RETA), *Earnings Before Interest and Tax to Total Assets* (EBITTA), *Market Value Equity to Book Value of Total Debt* (MVETL), *Sales to Total Assets* (STA) [8].

2. Model Ohlson

Model Ohlson dikembangkan pada tahun 1980, menggunakan Regresi Logistik pada 105 perusahaan yang dinyatakan bangkrut, sehingga dihasilkan sembilan rasio keuangan yang signifikan mempengaruhi *financial distress* [11], yaitu Ukuran Perusahaan (SIZE), *Total Liabilities to Total Assets* (TLTA), *Working Capital to Total Assets* (WCTA), *Current Liabilities to Current Assets* (CLCA), Perbandingan *Total Liabilities dan Total Assets* (OENEG), *Net Income to Total Assets* (NITA), *Cash Flows Operating to Total Liabilities* (CFOTL), Nilai *Net Income* (INTWO), dan Perubahan *Net Income* (CHIN)

C. Statistika Deskriptif

Data merupakan sekumpulan informasi yang dapat dianalisis untuk menghasilkan informasi yang lebih bermanfaat. Proses analisis tersebut memerlukan suatu metode yang disebut statistika. Statistika deskriptif adalah susunan angka yang memberikan gambaran mengenai data yang disajikan dalam bentuk tabel, diagram, ukuran penempatan, ukuran pemusatan, simpangan baku, dan regresi linear [10].

D. *Balancing Data*

Balancing dilakukan karena adanya ketidakseimbangan jumlah dataset antar kelas (*imbalance class*). Salah satu metode untuk mengatasi *imbalance class* adalah *Syntetic Minority Over-Sampling Technique* (SMOTE), dimana data pada kelas minoritas diperbanyak dengan menggunakan data sintesis yang berasal dari replikasi data pada kelas minoritas [7]. Selanjutnya, data sintesis diperoleh dengan rumus berikut.

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI
Annisa Salsabila Pratiwi, Galuh Oktavia Siswono, Prilyandari Dina Saputri

$$x_{syn} = x_i + (x_{knn} - x_i) \times \delta \quad (1.1)$$

dengan x_{syn} adalah hasil data sintesis, x_i adalah data yang akan direplikasi, x_{knn} adalah data yang memiliki jarak terdekat dari data yang akan direplikasi (k -nearest neighbors untuk x_i), dan δ adalah nilai *random* antara 0 dan 1.

E. Normalisasi Data

Normalisasi adalah penskalaan nilai dari data sehingga data terletak pada rentang tertentu [9]. Salah satu metode untuk melakukan normalisasi data adalah *Min-Max Normalization*. *Min-Max Normalization* dihitung dengan rumus:

$$V_{ij}' = \frac{V_{ij} - Min_j}{Max_j - Min_j} \quad (1.2)$$

dengan i adalah $1, 2, \dots, n$, j adalah $1, 2, \dots, p$, n adalah total observasi, p adalah total variabel prediktor, V_{ij}' adalah nilai hasil normalisasi data pada observasi ke- i variabel j , V_{ij} adalah nilai observasi ke- i pada variabel j , Min_j adalah nilai minimum data pada variabel j , Max_j adalah nilai maksimum data pada variabel j .

F. Feedforward Neural Network (FFNN)

Feedforward Neural Network (FFNN) merupakan salah satu dari model *Neural Network* yang banyak digunakan dalam berbagai bidang. Arsitektur FFNN terdiri dari *input layer*, *hidden layer*, dan *output* [3]. Kompleksitas dari FFNN tergantung dari jumlah *hidden layer* dan jumlah *neuron* pada masing-masing layer. Untuk menghasilkan *output* sesuai dengan nilai yang ditentukan, maka akan digunakan fungsi aktivasi. Salah satu fungsi aktivasi yang umum digunakan untuk klasifikasi biner adalah sigmoid biner dengan rumus:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1.3)$$

dimana x adalah nilai masukan dari *neuron* atau lapisan sebelumnya.

Untuk memperoleh bobot dengan nilai error minimal, digunakan algoritma *Backpropagation* [13]. Sistem kerja *Backpropagation* adalah jika *output* yang dihasilkan tidak sesuai, maka bobot diperbaharui supaya dapat menghasilkan nilai *error* yang kecil dan mendekati nilai yang sebenarnya.

G. Evaluasi Performa Model

Sebelum menghitung performa model, terlebih dahulu dibentuk *confusion matrix*, yaitu tabel yang menunjukkan jumlah data uji yang diklasifikasikan dengan benar dan salah [14].

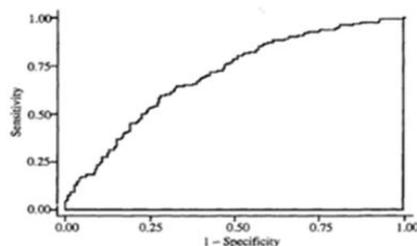
Tabel 1.1. Confusion Matrix

<i>Predicted</i>	<i>Actual</i>	
	<i>Non-Default (0)</i>	<i>Default (0)</i>
<i>Non-Default (0)</i>	<i>True Negative (TN)</i>	<i>False Negative (FN)</i>
<i>Default (1)</i>	<i>False Positive (FP)</i>	<i>True Positive (TP)</i>

Evaluasi performa model dapat didasarkan pada akurasi, yaitu ukuran yang menggambarkan seberapa akurat model dapat mengklasifikasikan observasi secara benar dengan rumus [6]:

$$Accuracy = \frac{TP + TN}{FP + FN + TP + TN} \quad (1.4)$$

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI
Annisa Salsabila Pratiwi, Galuh Oktavia Siswono, Prilyandari Dina Saputri



Gambar 1.1. Kurva ROC

Sumber : Hosmer & Lemeshow

Selain akurasi, dapat dilihat melalui nilai *Area Under Curve* (AUC), yaitu luas area di bawah kurva yang merepresentasikan hubungan antara *Sensitivity/TP_{rate}* (observasi yang diprediksi mengalami *financial distress* terhadap keseluruhan observasi yang mengalami *financial distress*) dan *1-Specificity/FP_{rate}* (observasi yang mengalami *financial distress* terhadap seluruh observasi yang tidak mengalami *financial distress*) [6]. Pada klasifikasi biner, luas AUC dapat dihitung melalui Persamaan berikut [7]:

$$AUC = \frac{1 + TP_{rate} - FP_{rate}}{2} \quad (1.5)$$

2. METODOLOGI PENELITIAN

Data yang digunakan merupakan data sekunder berupa *financial statement*, data harga saham, dan data GNP (*Gross National Product*) sebanyak 27 periode, mulai kuartal I tahun 2016 hingga kuartal III tahun 2022. Pemilihan sampel penelitian didasarkan pada kriteria yaitu perusahaan sektor Properti dan *Real Estate* yang terdaftar di Bursa Efek Indonesia (BEI) periode 2016 – 2022 dan perusahaan yang menerbitkan *financial statement* secara lengkap selama periode penelitian. Berdasarkan kriteria tersebut, maka didapat 19 perusahaan yang dijadikan sebagai sampel penelitian. Adapun langkah-langkah penelitian ini adalah sebagai berikut.

- a. Melakukan studi literatur.
- b. Mengumpulkan data sekunder yang akan digunakan dan menghitung rasio-rasio keuangan Altman dan Ohlson.
- c. Menentukan status awal kondisi keuangan berdasarkan *Earnings Per Share*, dimana jika terjadi selama 3 periode berturut-turut maka diklasifikasikan mengalami *financial distress*.
- d. Melakukan analisis statistika deskriptif.
- e. Membagi data menjadi data *training* dan data *testing*.
- f. Melakukan proses *balancing* pada data *training*.
- g. Melakukan normalisasi pada data.
- h. Melakukan analisis rasio keuangan model Altman dan model Ohlson dengan menggunakan *Feedforward Neural Network*, menggunakan algoritma *backpropagation*. Proses pembentukan model dilakukan dengan jumlah *hidden neuron* satu hingga lima dan dilakukan sebanyak 20 replikasi inisiasi bobot awal.
- i. Membandingkan model rasio keuangan Altman dan Ohlson berdasarkan nilai akurasi dan AUC. Rasio Keuangan terbaik dipilih berdasarkan nilai akurasi dan AUC terbesar.
- j. Menarik kesimpulan.

3. HASIL DAN PEMBAHASAN

A. Statistika Deskriptif

Berikut merupakan statistika deskriptif dari setiap rasio keuangan secara keseluruhan.

Tabel 3.1. Analisis Deskriptif Variabel Penelitian

Variabel	Y = 0			Y = 1		
	Mean	Med	Std	Mean	Med	Std
WCTA	0,256	0,218	0,305	0,208	0,210	0,255
RETA	0,312	0,307	0,357	-0,001	0,131	0,669
EBITTA	0,037	0,027	0,042	-0,008	-0,002	0,033
MVETL	0,867	0,005	2,661	0,160	0,005	0,225
STA	0,098	0,081	0,078	0,055	0,038	0,054
SIZE	5,297	6,176	1,373	4,987	5,919	1,413
TLTA	0,365	0,338	0,260	0,367	0,308	0,208
CLCA	0,494	0,372	0,397	0,705	0,357	0,839
NITA	0,030	0,017	0,045	-0,024	-0,014	0,033
CFOTL	0,048	0,014	0,344	-0,027	-0,027	0,125
CHIN	-0,051	0,163	1,747	-0,173	0,087	2,595

Berdasarkan Tabel 3.1, terdapat perbedaan signifikan antara distribusi variabel pada observasi yang mengalami *financial distress* ($Y=1$) dan tidak mengalami *financial distress* ($Y=0$). Pada observasi yang tidak mengalami *financial distress*, hanya variabel SIZE dan CHIN yang memiliki nilai *mean* lebih rendah daripada median. Berbeda halnya pada observasi yang mengalami *financial distress*, dimana variabel WCTA, RETA, EBITTA, SIZE, NITA, CFOTL, dan CHIN memiliki nilai *mean* lebih rendah daripada median. Dilihat dari nilai *mean* kedua kelas, variabel WCTA, RETA, EBITTA, MVETL, STA, SIZE, NITA, CFOTL, dan CHIN memiliki nilai *mean* yang lebih tinggi pada observasi yang tidak mengalami *financial distress*, namun pada variabel TLTA dan CLCA, nilai *mean* lebih tinggi pada observasi yang mengalami *financial distress*.

Tabel 3.2. Analisis Deskriptif Variabel Nominal

Variabel	Kode	
	0	1
OENEG	511	2
INTWO	379	134

Berdasarkan Tabel 3.2, hanya 2 observasi pada OENEG yang memiliki nilai *Total Liabilities* lebih besar dari *total Asset*, hal tersebut menunjukkan bahwa secara umum perusahaan Properti dan *Real Estate* tidak mengalami kendala dalam memenuhi kewajiban. Selain itu, terdapat 134 observasi yang mengalami *net income* negatif, dimana 97 diantaranya terjadi pada kategori *financial distress*. Hal tersebut menunjukkan bahwa perusahaan yang mengalami *net income* negatif, terutama yang terjadi secara terus menerus berpotensi mengalami *financial distress*.

B. Pembagian Data *Training* dan Data *Testing*

Pembagian data *training* dan *testing* dilakukan dengan proporsi 80:20, 80% untuk data *training* dan 20% sebagai data *testing* sebagai berikut.

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

Annisa Salsabila Pratiwi, Galuh Oktavia Siswono, Prilyandari Dina Saputri

Tabel 3.3. Pembagian Data *Training* dan Data *Testing*

Observasi	Data <i>Training</i>	Data <i>Testing</i>
Y=0	328	83
Y=1	81	21
Total	409	104

C. *Balancing* Data

Pada penelitian ini, data *training* yang akan digunakan mengalami *imbalance class* seperti pada Tabel 5. Maka dari itu, dilakukan *balancing* pada data *training* dengan proporsi 60:40 dan 50:50. Pembagian data *training* dan *testing* setelah proses *balancing* dapat dilihat pada Tabel 3.4.

Tabel 3.4. Pembagian Data *Training* dan Data *Testing* setelah *Balancing*

Observasi	Data <i>Training</i>		Data <i>Testing</i>
	60:40	50:50	
Y=0	328	328	83
Y=1	219	328	21
Total	547	656	104

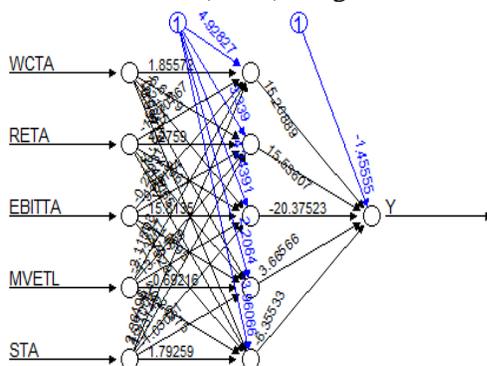
D. Normalisasi Data

Normalisasi data bertujuan untuk meningkatkan performa model dan mempercepat proses konvergensi data selama proses pelatihan. Pada penelitian ini, data akan dinormalisasi ke dalam range 0 sampai 1 sesuai dengan output prediksi yang diharapkan pada model.

E. Pemodelan Rasio Keuangan Altman

1) Pemodelan Rasio Keuangan Altman Tanpa *Balancing*

Pembentukan model Rasio Keuangan Altman tanpa *balancing* dimulai dengan mencari *hidden neuron* terbaik melalui 20 replikasi inisiasi bobot awal. *Hidden neuron* yang terbaik merupakan *hidden neuron* yang menghasilkan nilai AUC dan akurasi terbesar. Model *Feedforward Neural Network* (FFNN) terbaik pada data *training* tanpa *balancing* terdapat ketika jumlah *neuron* di *hidden layer* sebanyak lima dengan jumlah *epoch* sebesar 116.842. Maka dari itu, model yang terbentuk terdiri dari *input layer* dengan lima *neuron*, satu *hidden layer* dengan lima *neuron*, dan *output layer* dengan satu *neuron* atau FFNN (5-5-1) dengan arsitektur sebagai berikut.



Gambar 3.1. Arsitektur Altman Tanpa *Balancing*

Gambar 3.1 menunjukkan bahwa model FFNN menghasilkan 2 parameter yaitu parameter bobot (garis hitam) dan parameter bias (garis biru). Nilai-nilai bobot dan bias pada *input layer* terhadap *hidden layer* digunakan membentuk Persamaan 3.1 hingga Persamaan 3.5, sedangkan nilai bobot dan bias pada *hidden layer* menuju *output layer* digunakan untuk membentuk Persamaan 3.0 sebagai berikut.

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI
Annisa Salsabila Pratiwi, Galuh Oktavia Siswono, Prilyandari Dina Saputri

$$\hat{y} = \frac{1}{1 + e^{-(-1,4555+15,208 Z_1+15,536 Z_2-20,3752Z_3+3,665Z_4-6,355Z_5)}} \quad (3.0)$$

$$Z_1 = \frac{1}{1 + e^{-(4,928+1,855X_1-18,707X_2- 0,279X_3- 2,11 X_4+2,36 X_5)}} \quad (3.1)$$

$$Z_2 = \frac{1}{1 + e^{-(3,339-6,647 X_1+4,275X_2-9,091X_3-7,732 X_4+ 15,1X_5)}} \quad (3.2)$$

$$Z_3 = \frac{1}{1 + e^{-(-4,243+0,213X_1-1,29X_2+15,8135X_3+ 15,5339 X_4+1,7315X_5)}} \quad (3.3)$$

$$Z_4 = \frac{1}{1 + e^{-(2,206-0,084X_1- 2,49X_2- 1,156X_3- 0,692X_4-1,03X_5)}} \quad (3.4)$$

$$Z_5 = \frac{1}{1 + e^{-(-3,960-0,537X_1+3,195X_2+ 2,370X_3-0,203 X_4+1,792X_5)}} \quad (3.5)$$

Berikut merupakan contoh penggunaan Persamaan 3.0 hingga Persamaan 3.5 pada data *testing* pertama. Diketahui nilai WCTA (X_1) = 0,3488, RETA (X_2) = 0,7544, EBITTA (X_3) = 0,4024, MVETL (X_4) = 0,0394, dan STA (X_5) = 0,1170. Kemudian, nilai-nilai rasio tersebut disubstitusikan ke Persamaan 31 hingga 35, sehingga didapatkan hasil $Z_1=0,0002$, $Z_2=0,8858$, $Z_3=0,8761$, $Z_4=0,4217$, dan $Z_5=0,3585$. Selanjutnya, nilai Z_1 hingga Z_5 tersebut disubstitusikan ke Persamaan 3.0, sehingga diperoleh hasil $\hat{y}_1=0,00188$.

Hasil prediksi (\hat{y}_1) untuk data *testing* pertama adalah 0,00188. Karena nilai prediksi tersebut kurang dari 0,5 maka data *testing* pertama tersebut diklasifikasikan ke dalam kategori 0 atau tidak mengalami *financial distress*. Proses yang sama dilakukan pada seluruh observasi yang digunakan sebagai data *testing*. Selanjutnya, nilai hasil prediksi tersebut dibandingkan dengan nilai *actual*, maka didapatkan *confusion matrix* seperti berikut.

Tabel 3.5. *Confusion Matrix* Altman Tanpa *Balancing*

<i>Predicted</i>	<i>Actual</i>	
	$Y = 0$	$Y = 1$
$Y = 0$	69	4
$Y = 1$	14	17

Berdasarkan Tabel 3.5, maka dapat dilakukan perhitungan performansi model sebagai berikut.

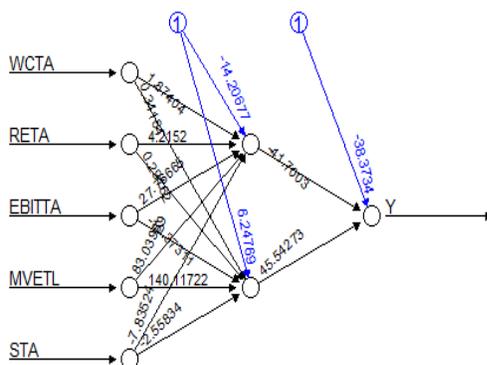
$$\text{Akurasi} = \frac{69 + 17}{69 + 4 + 14 + 17} = 0,8269$$

$$\text{AUC} = \frac{1 + \frac{17}{17 + 4} - \frac{14}{14 + 69}}{2} = 0,8204$$

2) Pemodelan Rasio Keuangan Altman dengan *Balancing*

Model *Feedforward Neural Network* (FFNN) dengan nilai akurasi dan AUC tertinggi pada data *training* yang melalui *balancing* sebesar 60:40 dengan 20 replikasi pada inisiasi bobot awal terdapat ketika jumlah *neuron* di *hidden layer* sebanyak dua. Sehingga model yang terbentuk terdiri dari *input layer* dengan lima *neuron*, satu *hidden layer* dengan dua *neuron*, dan *output layer* dengan satu *neuron*. Maka model yang terbentuk adalah FFNN (5-2-1) dengan arsitektur pada Gambar 3.

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI
Annisa Salsabila Pratiwi, Galuh Oktavia Siswono, Prilyandari Dina Saputri



Gambar 3.2. Arsitektur Altman dengan *Balancing*

Kemudian dilakukan validasi model FFNN (5-2-1) tersebut pada data *testing*, sehingga menghasilkan *confussion matrix* sebagai berikut.

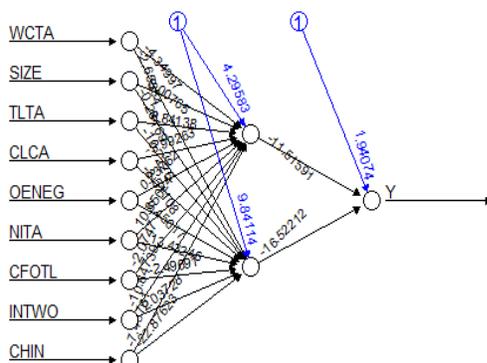
Tabel 3.6. *Confussion Matrix* Altman dengan *Balancing*

<i>Predicted</i>	<i>Actual</i>	
	$Y = 0$	$Y = 1$
$Y = 0$	71	4
$Y = 1$	12	17

F. Pemodelan Rasio Keuangan Ohlson

1) Pemodelan Rasio Keuangan Ohlson Tanpa *Balancing*

Model *Feedforward Neural Network* (FFNN) dengan nilai akurasi dan AUC tertinggi pada data *training* tanpa *balancing* dengan 20 replikasi pada inisiasi bobot awal terdapat ketika jumlah *neuron* di *hidden layer* sebanyak dua. Sehingga model yang terbentuk terdiri dari *input layer* dengan lima *neuron*, satu *hidden layer* dengan dua *neuron*, dan *output layer* dengan satu *neuron*, dengan arsitektur sebagai berikut.



Gambar 3.3. Arsitektur Ohlson Tanpa *Balancing*

Kemudian dilakukan validasi pada model FFNN (9-2-1) tersebut menggunakan data *testing* sehingga menghasilkan *confussion matrix* sebagai berikut.

Tabel 3.7. *Confussion Matrix* Ohlson Tanpa *Balancing*

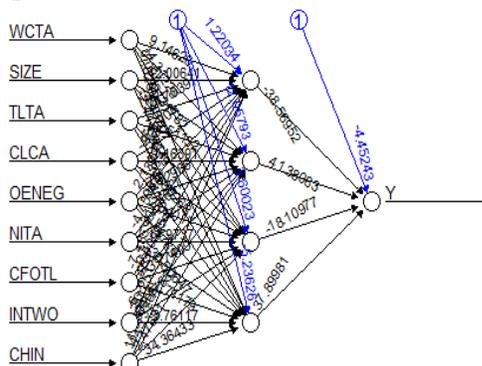
<i>Predicted</i>	<i>Actual</i>	
	$Y = 0$	$Y = 1$
$Y = 0$	78	3
$Y = 1$	5	18

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

Annisa Salsabila Pratiwi, Galuh Oktavia Siswono, Prilyandari Dina Saputri

2) Pemodelan Rasio Keuangan Ohlson Dengan *Balancing*

Model *Feedforward Neural Network* (FFNN) dengan nilai akurasi dan AUC tertinggi pada data *training* yang melalui *balancing* sebesar 60:40 dengan 20 replikasi pada inisiasi bobot awal terdapat ketika jumlah *neuron* di *hidden layer* sebanyak empat. Sehingga model yang terbentuk terdiri dari *input layer* dengan lima *neuron*, satu *hidden layer* dengan empat *neuron*, dan *output layer* dengan satu *neuron*, seperti Gambar 5.



Gambar 3.3. Arsitektur Ohlson Dengan *Balancing*

Kemudian dilakukan validasi model FFNN (9-4-1) tersebut menggunakan data testing, sehingga menghasilkan *confusion matrix* sebagai berikut.

Tabel 3.7. *Confussion Matrix* Ohlson dengan *Balancing*

<i>Predicted</i>	<i>Actual</i>	
	<i>Y = 0</i>	<i>Y = 1</i>
<i>Y = 0</i>	79	3
<i>Y = 1</i>	4	18

G. Perbandingan Rasio Keuangan Altman dan Ohlson

Perbandingan akurasi dan AUC Rasio keuangan Altman dan Ohlson adalah sebagai berikut.

Tabel 3.8. Nilai akurasi dan AUC Rasio Keuangan Altman dan Ohlson

Rasio Keuangan	Data	Akurasi	AUC	
Altman	Tanpa <i>Balancing</i>	0,8269	0,8204	
	<i>Balancing</i>	50:50	0,8654	0,6667
		60:40	0,8462	0,8325
Ohlson	Tanpa <i>Balancing</i>	0,9231	0,8985	
	<i>Balancing</i>	50:50	0,9038	0,8686
		60:40	0,9327	0,9045

Berdasarkan Tabel 3.8, dapat disimpulkan bahwa model rasio keuangan Ohlson dengan proses *balancing* sebesar 60:40 adalah rasio keuangan yang terbaik untuk mengklasifikasikan *financial distress* pada perusahaan sektor Properti dan *Real Estate* yang terdaftar di Bursa Efek Indonesia periode 2016 hingga 2022. Evaluasi model ini didasarkan pada nilai akurasi dan AUC tertinggi dibandingkan model lainnya. Rasio keuangan Ohlson memiliki beberapa keunggulan dalam mengklasifikasi *financial distress*. Pertama, model Ohlson menggunakan sembilan rasio keuangan yang terbagi menjadi empat ukuran dasar. Kedua, terdapat variabel non-keuangan yaitu ukuran perusahaan (SIZE), dimana berdasarkan beberapa penelitian sebelumnya, variabel ini memiliki pengaruh signifikan terhadap *financial distress* ^[16]. Ketiga, dapat diterapkan pada

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

Annisa Salsabila Pratiwi, Galuh Oktavia Siswono, Prilyandari Dina Saputri

berbagai sektor industri dibandingkan dengan Altman yang dibangun hanya pada sektor manufaktur. Terakhir, jumlah sampel yang lebih besar, dimana model Ohlson dikembangkan dengan menggunakan data dari 105 perusahaan yang mengalami kebangkrutan dan 2058 perusahaan yang tidak mengalami kebangkrutan. Perbedaan dalam jumlah dan karakteristik sampel ini dapat mempengaruhi akurasi dan kesesuaian model yang dikembangkan.

4. KESIMPULAN

Berdasarkan hasil analisis dari penelitian tugas akhir yang telah dilakukan, didapatkan beberapa kesimpulan dan saran sebagai berikut.

1. Secara umum, perusahaan yang memiliki rasio likuiditas dengan nilai *Working Capital to Total Asset* (WCTA) rendah dan *Current Liabilities to Current Asset* (CLCA) tinggi, rasio profitabilitas rendah, rasio solvabilitas tinggi, rasio aktivitas rendah, rasio penilaian rendah, dan juga ukuran perusahaan yang rendah, cenderung mengalami *financial distress*.
2. Model terbaik dari masing-masing rasio keuangan:
 - a. Pada Rasio Keuangan Altman, model terbaik adalah pada data yang melalui *balancing* sebesar 60:40, dimana arsitektur yang terbentuk adalah FFNN (5-2-1) yang terdiri dari *input layer* dengan 5 *neuron*, 1 *hidden layer* dengan 2 *neuron*, dan *output layer* dengan 1 *neuron*, serta nilai akurasi sebesar 84,62% dan nilai AUC sebesar 0,8325.
 - b. Pada Rasio Keuangan Ohlson, model terbaik adalah pada data yang melalui *balancing* sebesar 60:40, dimana arsitektur yang terbentuk adalah FFNN (9-4-1) yang terdiri dari *input layer* dengan 9 *neuron*, 1 *hidden layer* dengan 4 *neuron*, dan *output layer* dengan 1 *neuron*, serta nilai akurasi 93,27% dan nilai AUC 0,9045.
3. Rasio keuangan terbaik dalam mengklasifikasikan *financial distress* perusahaan Properti dan *Real Estate* adalah Rasio Keuangan Ohlson dengan variabel prediktor berupa Ukuran Perusahaan (SIZE), *Total Liabilities to Total Asset* (TLTA), *Working Capital to Total Assets* (WCTA), *Current Liabilities to Current Assets* (CLCA), Perbandingan Total Liabilitas dan Total Aset (OENEG), *Net Income to Total Assets* (NITA), *Cash Flows Operating to Total Liabilities* (CFOTL), Nilai *Net Income* (INTWO), dan Perubahan *Net Income* (CHIN).

DAFTAR PUSTAKA

- [1] Altman, E. I. 1968. Financial Ratios, Discriminant Analysis and The Prediction of Corporate Bankruptcy. *The Journal of Finance*, vol. 23. no 4, pp. 589–609.
- [2] Fachrudin, K. A. 2008. *Kesulitan Keuangan Perusahaan Dan Personal*. USU Press.
- [3] Fausett, L. 1969. Fundamentals of neural Networks (Architectures, Algorithms, and Applications). In *IEEE Transactions on Computers*: vol. C–18, no. 6.
- [4] Febriana, K. 2021. *Analisis Penggunaan dan Tingkat Akurasi Model Altman Z-Score, Zmijewski (X-Score), dan Springate dalam Memprediksi Financial Distress pada Bank Syariah Devisa dan Non Devisa Periode 2015-2018*. Universitas Islam Negeri Walisongo.
- [5] Guénette, J. D., Kose, M. A., & Sugawara, N. 2022. Is a Global Recession Imminent? EFi Policy Note 4.
- [6] Huang, J., & Ling, C. X. 2005. Using AUC and accuracy in evaluating learning algorithms. *IEEE Transactions on Knowledge and Data Engineering*, vol. 17, no. 3, pp. 299–310.
- [7] Kurniawan, E., Nhita, F., Aditsania, A., & Saepudin, D. 2019. Algorithm and Synthetic Minority Over- sampling Technique (SMOTE) for Rainfall Forecasting in Bandung Regency. *2019 7th International Conference on Information and Communication Technology (ICoICT)*.
- [8] Mulyadi, D. 2020. Analysis Prediction of Bankruptcy Business by Using the Method Altman

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI
Annisa Salsabila Pratiwi, Galuh Oktavia Siswono, Prilyandari Dina Saputri

- Z-Score and Springate (Case Study in PT Holcim Indonesia TBK). *International Journal of Innovation, Creativity and Change*, vol. 12, no. 5, pp. 723–735.
- [9] Nasution, D. A., Khotimah, H. H., & Chamidah, N. 2019. Perbandingan Normalisasi Data untuk Klasifikasi Wine Menggunakan Algoritma K-NN. *Computer Engineering, Science and System Journal*, vol. 4, no. 1, p. 78.
- [10] Nasution, L. M. 2017. Statistik Deskriptif Leni Masnidar Nasution. *Hikmah*, vol. 14, no. 1, pp. 49–55.
- [11] Ohlson, J. A. 1980. Financial Ratios and the Probabilistic Prediction of Bankruptcy. *Journal of Accounting Research*, vol. 18, no. 1, pp. 109–131.
- [12] Platt, H. D., & Platt, M. B. 2006. Understanding Differences Between Financial Distress and Bankruptcy. *Review of Applied Economics*, vol. 2, no. 2.
- [13] Putri, R., & Saputro, A. H. 2019. Implementation of neural network classification for diabetes mellitus prediction system through iridology image. *2019 6th International Conference on Information Technology, Computer and Electrical Engineering, ICITACEE 2019*.
- [14] Rahman, M. F., Alamsah, D., Darmawidjadja, M. I., & Nurma, I. 2017. Klasifikasi Untuk Diagnosa Diabetes Menggunakan Metode Bayesian Regularization Neural Network (RBNN). *Jurnal Informatika*, vol. 11, no. 1, p. 36.
- [15] Salim, S. N., & Dillak, V. J. 2021. Pengaruh Ukuran Perusahaan, Biaya Agensi Manajerial, Struktur Modal dan Gender Diversity terhadap Financial Distress. *Jurnal Ilmiah MEA (Manajemen, Ekonomi, dan Akuntansi)*, vol. 5, no. 3, pp. 182–198.
- [16] Saputri, P. D., & Oktaviana, P. P. 2023. Comparison of Feedforward Neural Network and Classical Statistics Methods: Application in Finance. *Jurnal Matematika, Statistika dan Komputasi*, vol. 19, no. 3, pp. 537–548.
- [17] Wijaksana, S. 2023. *Analisis Perbandingan Klasifikasi Financial Distress Perusahaan Sektor Transportasi Di Bursa Efek Indonesia Menggunakan Artificial Neural Network dan Support Vector Machine*. Institut Teknologi Sepuluh Nopember.
- [18] Yuniarti, I. 2016. *Prediksi Financial Distress Perusahaan Sektor Manufaktur dan Industri Penghasil Bahan Baku Utama yang Terdaftar di BEI menggunakan Analisis Diskriminan, Regresi Logistik Biner, dan Feedforward Neural Network*. Institut Teknologi Sepuluh Nopember.