

## Deteksi Dini Financial Distress Pada Perusahaan Sektor Teknologi di Bursa Efek Indonesia Menggunakan *Artificial Neural Network* dan *Support Vector Machine*

Ni Luh Eva Pradnyaningsih<sup>1</sup>, Noviyanti Santoso<sup>1\*</sup>, Fausania Hibatullah<sup>1</sup>

<sup>1</sup>Departemen Statistika Bisnis, Fakultas Vokasi, Institut Teknologi Sepuluh Nopember

\*Email: noviyanti.santoso@its.ac.id

### Info Artikel

#### Kata Kunci :

artificial neural network,  
financial distress,  
support vector machine,  
teknologi

#### Keywords :

artificial neural network,  
financial distress,  
support vector machine,  
technology

#### Tanggal Artikel

Dikirim : 21 Januari 2025

Direvisi : 27 Mei 2025

Diterima : 31 Mei 2025

### Abstrak

Kondisi ekonomi dan geopolitik di Indonesia diperkirakan akan memburuk pada beberapa tahun kedepan yang disebabkan oleh beberapa faktor diantaranya inflasi dan biaya operasional yang tinggi. Hal ini berdampak pada minat investor dalam berinvestasi pada perusahaan. Salah satu perusahaan yang paling berdampak besar adalah perusahaan sektor teknologi. Industri teknologi di Indonesia menghadapi tantangan pada pangsa pasar yang relatif rendah dibandingkan pasar global dimana banyak saham teknologi di Indonesia masih tertinggal jauh dibandingkan negara-negara maju. Akibat hal tersebut investor lebih memilih berinvestasi pada emiten yang minim risiko. Penurunan ini memengaruhi kemampuan perusahaan-perusahaan teknologi untuk menarik investasi yang dibutuhkan untuk bertahan dan berkembang. Beberapa perusahaan di sektor teknologi telah mengalami perubahan signifikan dalam kinerja keuangan mereka, menunjukkan adanya potensi kesulitan keuangan. Kesulitan keuangan terjadi ketika kinerja keuangan perusahaan menurun dari waktu ke waktu, yang pada gilirannya memengaruhi stabilitas sistem keuangan dan sumber daya manusia perusahaan. Oleh karena itu, penelitian ini bertujuan untuk memprediksi apakah perusahaan-perusahaan di sektor teknologi di Indonesia akan mengalami kesulitan keuangan di masa depan atau tidak dengan menggunakan metode *Artificial Neural Network* dan *Support Vector Machine*. Hasil penelitian menunjukkan bahwa ANN lebih unggul dalam memprediksi kinerja keuangan perusahaan dengan akurasi sebesar 95,65%, sensitivitas mencapai 100%, dan *F1 Score* yaitu 80%, lebih lanjut rasio PER memiliki pengaruh besar dalam memprediksi risiko ini. Selain itu, aplikasi berbasis *web* yang dikembangkan menggunakan Streamlit memungkinkan pengguna untuk mendeteksi dini kondisi keuangan perusahaan.

### Abstract

*The economic and geopolitical conditions in Indonesia are expected to deteriorate in the coming years due to several factors, including inflation and high operational costs. This affects investor interest in investing in companies. One of the most significantly impacted sectors is technology companies. The technology industry in Indonesia faces challenges with a relatively low market share compared to the global market, where many technology stocks in Indonesia lag significantly behind those in developed countries. As a result, investors prefer to invest in issuers with minimal risk. This decline affects the ability of technology companies to attract the investment needed to survive and grow. Some companies in the technology sector have experienced significant changes in their financial performance, indicating potential financial difficulties. Financial difficulties occur when a company's financial performance declines over time, which in turn affects the stability of the financial system and the company's human resources. Therefore, this study aims to predict whether technology companies in Indonesia will experience financial distress in the future using Artificial Neural Network and Support Vector Machine methods. The results of the study indicate that ANN outperforms other models in predicting the financial performance of companies with the accuracy reach 95,65%, perfect sensitivity of 100%, and F1 Score is 80%, with the PER ratio having a significant impact on forecasting this risk. Additionally, the web-based application developed using Streamlit enables users to detect companies financial conditions early.*

## 1. PENDAHULUAN

Tantangan perekonomian Indonesia dalam lima tahun ke depan diperkirakan meningkat akibat ketidakstabilan ekonomi dan geopolitik global, serta ketidakpastian politik domestik. Salah satunya yang terdampak yaitu mengganggu kinerja investasi yang ada di dalam negeri. [1] Hal ini disebabkan oleh adanya kenaikan inflasi dan suku bunga. Kenaikan inflasi dan suku bunga meningkatkan biaya operasional perusahaan, menaikkan harga jasa, dan mengurangi pendapatan akibat penurunan permintaan. [2] Sehingga, perusahaan kesulitan mendapatkan pinjaman dengan suku bunga yang rendah dan berdampak pada keuntungan yang akan diperoleh investor. Hal ini membuat investor enggan membeli saham. Salah satu perusahaan yang terdampak besar adalah perusahaan teknologi. Berdasarkan laman Bursa Efek Indonesia (BEI), indeks IDX Sektor Teknologi mengalami penurunan sebesar 20,06% secara *year to date* (YtD), menjadikannya indeks *sectoral* dengan kinerja terburuk sepanjang tahun 2024.

Beberapa perusahaan teknologi yang mengalami kerugian signifikan hingga tahun 2024 diantaranya PT GoTo Gojek Tokopedia Tbk (GOTO) mencatat kerugian Rp90 Triliun dengan penurunan harga saham sebesar 4,17%. [3] PT Anabatic Technologies (ATIC) mengalami penurunan laba bersih 38% menjadi Rp23,66 Miliar sepanjang 2023. [4] PT Envy Technologies Indonesia Tbk (ENVY) rugi Rp30,8 Miliar sepanjang 2023 dan terancam delisting karena tidak melaporkan kewajibannya sejak tahun 2020. [5] PT Limas Indonesia Makmur Tbk (LIMAS) juga berpotensi delisting setelah sahamnya disuspensi 18 bulan. [6] Kegagalan keuangan atau kerugian yang dialami perusahaan-perusahaan tersebut menunjukkan adanya tekanan yang signifikan pada kinerja keuangan yang mungkin mengindikasikan kondisi *financial distress*.

*Financial distress* adalah situasi di mana perusahaan gagal memenuhi kewajibannya, yang dapat merusak sistem keuangan dan sumber daya manusia. [7] Kondisi ini ditandai dengan penurunan kinerja keuangan selama tiga tahun berturut-turut. Perusahaan berusaha mengantisipasi risiko keuangan dengan memprediksi *financial distress*. Prediksi ini biasanya dilakukan oleh pihak eksternal seperti investor, kreditor, dan auditor, yang merespon sinyal distress seperti hilangnya kepercayaan pelanggan dan masalah kredit.

Studi mengenai prediksi *financial distress* pada perusahaan yang beroperasi di berbagai sektor, termasuk manufaktur, perdagangan, dan jasa yang terdaftar di Bursa Efek Istanbul pernah dilakukan oleh Aydin dkk. [8] Penelitian tersebut menganalisa 240 perusahaan yang terdaftar di Bursa Efek Istanbul (BIST) menggunakan model *Artificial Neural Network* (ANN) dan *Decision Tress* (DT). Hasil pada penelitian tersebut menunjukkan bahwa metode ANN lebih baik yaitu akurasi sebesar 93,10% daripada metode DT sebesar 84,03% karena nilai akurasi klasifikasinya yang lebih unggul. Selain itu, penelitian lain terkait penentuan kebangkrutan perusahaan menyebutkan bahwa salah satu metode yang diketahui mampu menghasilkan nilai akurasi yang tinggi yaitu SVM dengan sigmoid kernal dengan akurasi mencapai 94%. [9]

Berdasarkan uraian di atas, maka pada penelitian ini dilakukan deteksi dini *financial distress* pada perusahaan sektor teknologi di Bursa Efek Indonesia dari tahun 2020-2023. Menggunakan data tahun 2020-2023 untuk memprediksi *financial distress* pada perusahaan sektor teknologi penting karena periode ini mencakup dampak signifikan dari pandemi COVID-19, percepatan inovasi teknologi, volatilitas pasar di mana periode 2020-2023 mencakup fluktuasi pasar yang signifikan, baik akibat pandemi maupun faktor lainnya seperti perubahan kebijakan ekonomi, suku bunga, dan inflasi, dan perubahan valuasi saham yang memengaruhi kondisi keuangan perusahaan

## 2. TINJAUAN PUSTAKA

### 2.1 *Financial Distress*

*Financial distress* adalah suatu fenomena yang menunjukkan tren penurunan kinerja keuangan suatu perusahaan. Biasanya, *financial distress* merupakan tahap awal sebelum terjadinya kebangkrutan. [10] Terjadinya *financial distress* ketika sebuah perusahaan mengalami kesulitan keuangan yang dapat disebabkan oleh berbagai faktor. Menurut Damoran (1997), faktor penyebab *financial distress* dalam perusahaan lebih bersifat mikro. Faktor-faktor internal perusahaan tersebut meliputi:

1. Kesulitan arus kas
2. Besarnya jumlah utang
3. Kerugian dalam kegiatan operasional perusahaan selama beberapa tahun

Kondisi *financial distress* suatu perusahaan dapat diprediksi dengan menggunakan model *Zmijewski*. Model *Zmijewski* dapat dilihat pada persamaan (1). [11]

$$X_{score} = -4,336 - 4,513A + 5,679B - 0,004C \quad (1)$$

Keterangan :

$A$  = Return on Asset (ROA)

$B$  = Debt to Asset Ratio (DAR)

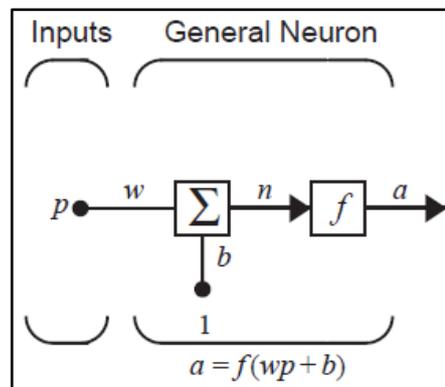
$C$  = Current Ratio

Hasil pemodelan akan dikategorikan menjadi dua berdasarkan nilai  $X_{score}$ , jika  $X_{score} < 0$  akan dikategorikan perusahaan *non financial distress*, sedangkan jika  $X_{score} \geq 0$  akan dikategorikan perusahaan *financial distress*. [12]

## 2.2 Artificial Neural Network (ANN)

*Artificial Neural Network* (ANN) atau jaringan saraf tiruan adalah sistem komputasi yang arsitektur dan operasinya terinspirasi oleh cara kerja sel-sel syaraf di dalam otak, dan merupakan model dari jaringan syaraf biologis.

Komponen dalam setiap sistem ANN dapat dianalogikan dengan bagian-bagian dari sistem *neuron* manusia, seperti *dendrit* (bagian yang menerima masukan/input/sinyal), badan sel (mengolah masukan), dan akson (mentransmisikan masukan tersebut ke *neuron* lain/*output*) [13] seperti yang disajikan pada Gambar 1 berikut.

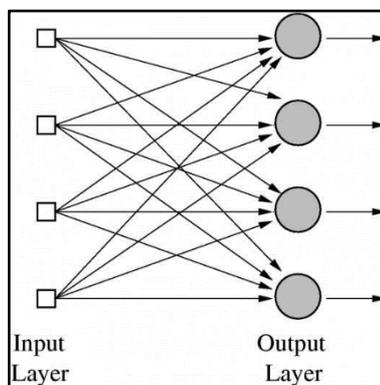


Gambar 1. Struktur ANN

Setiap informasi yang diterima oleh dendrit (*input*) akan dijumlahkan dan dikirim melalui akson menuju dendrit (*output*) untuk diteruskan ke dendrit (*input*) *neuron* lainnya. Informasi akan diterima oleh *neuron* lain jika memenuhi batasan tertentu yang disebut nilai ambang (*threshold*). *Neuron* yang telah menerima informasi dan mengirimkannya ke *neuron* lain dianggap teraktivasi. *Neuron* menerima informasi dari *neuron* lain dalam bentuk nilai yang disebut bobot. Bobot juga menunjukkan seberapa kuat hubungan antar *neuron*.

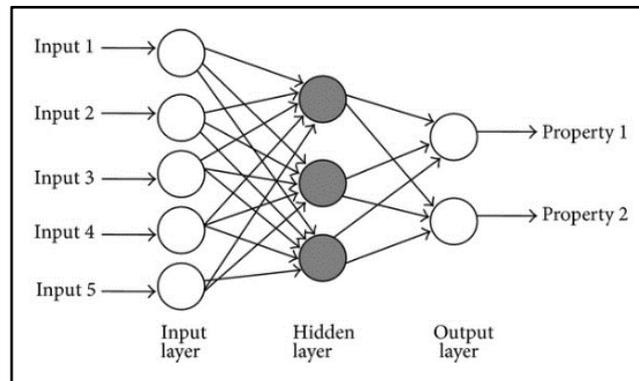
Arsitektur ANN merupakan pola hubungan antar *neuron*. Beberapa arsitektur jaringan syaraf antara lain sebagai berikut.

1. Jaringan dengan lapisan tunggal (*single layer network*) : jaringan ini tidak memiliki *hidden layer* seperti ilustrasi pada Gambar 2.



Gambar 2. Single Layer Network

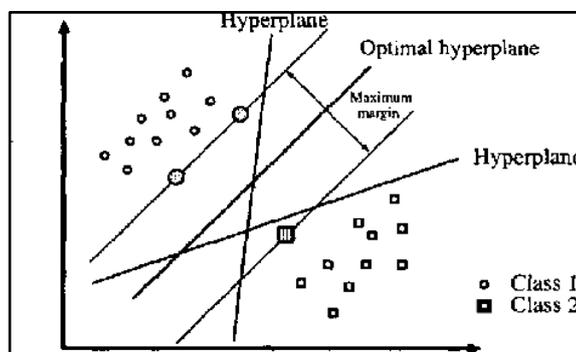
2. Jaringan dengan banyak lapisan (*multilayer network*) : jaringan dengan banyak lapisan memiliki 1 atau lebih lapisan di antara lapisan input dan lapisan output sesuai pada Gambar 3.



Gambar 3. *Multilayer Network*

### 2.3 Support Vector Machine (SVM)

*Support Vector Machine* (SVM) dikembangkan oleh Oser, Guyon, dan Vapnik, dan pertama kali diperkenalkan pada tahun 1992. Pada dasarnya, SVM adalah *classifier linear*. Namun, teknologi ini kemudian diperluas untuk menangani masalah non-linear dengan menerapkan konsep *kernel trick* di ruang kerja berdimensi tinggi. Ide dasar dari metode SVM adalah dengan memaksimalkan batas *hyperplane* yang berfungsi sebagai pemisah antar dua kelas pada *input space* [14]. Ilustrasi mengenai *hyperplane* pada SVM ditunjukkan pada Gambar 4 berikut ini.



Gambar 4. *Alternatif Hyperplane*

*Hyperplane* pemisah terbaik antara dua kelas dapat ditemukan dengan mengukur margin *hyperplane* dan mencari nilai maksimalnya. Margin adalah jarak antara *hyperplane* dan data terdekat dari setiap kelas. Data yang paling dekat dengan *hyperplane* disebut sebagai *support vectors*.

Menurut Prasetyo (2014), kernel yang umum dipakai pada SVM dapat dilihat pada Tabel 1:

Tabel 1. *Kernel yang umum dipakai dalam SVM*

Jenis Kernel	Definisi
<i>Linear</i>	$K(\vec{x}_i, \vec{x}_j) = \vec{x}_i^T \cdot \vec{x}_j$
<i>Radial Basis Function (RBF)</i>	$K(\vec{x}_i, \vec{x}_j) = \exp\left(-\frac{\ \vec{x}_i - \vec{x}_j\ ^2}{2\sigma^2}\right); \gamma = \frac{1}{2\sigma^2}$

## 2.4 Synthetic Minority Oversampling Technique (SMOTE)

*Syntetic Minority Oversampling Technique* (SMOTE) adalah salah satu metode *oversampling* yang ditemukan oleh Chawla (2003) berupa teknik penambahan jumlah sampel pada kelas minor dengan melakukan replikasi data pada kelas minor secara acak sehingga menghasilkan jumlah data yang sama dengan data pada kelas data mayor [15]. Data yang direplikasi dalam algoritma SMOTE berasal dari kelas minoritas. Algoritma ini menggunakan metode *k-nearest neighbors* (KNN), yang termasuk dalam kategori metode statistik nonparametrik.

$$x_{knn} = d(X_{3j}, X_{1j}) = \sqrt{(x_{31} - x_{11})^2 + \dots + (x_{ij} - y_{ij})^2} \quad (2)$$

Secara umum rumus menentukan data sintesis sebagai berikut.

$$x_{syn} = x_i + (x_{knn} - x_i)\delta \quad (3)$$

Keterangan :

$x_{syn}$  : data sintesis hasil dari replikasi

$x_i$  : data yang akan direplikasi

$x_{knn}$  : data yang memiliki jarak terdekat dari data yang akan direplikasi

$\delta$  : bilangan random antara 0 dan 1

## 2.5 SHAP Values

SHAP (*SHapley Additive exPlanations*) values adalah cara umum untuk mendapatkan penjelasan yang konsisten dan objektif tentang bagaimana setiap fitur memengaruhi prediksi model. Nilai SHAP didasarkan pada teori permainan dan memberikan nilai kepentingan kepada setiap fitur dalam model. Fitur dengan nilai SHAP positif memiliki dampak positif pada prediksi, sedangkan fitur dengan nilai negatif memiliki dampak negatif. Besar kecilnya nilai menunjukkan seberapa kuat pengaruhnya [16]. SHAP digunakan untuk mengukur seberapa penting setiap variabel *input* bagi model untuk memprediksi. Secara sistematis nilai Shapley dihitung sebagai berikut.

$$\phi_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(|N|-|S|-1)!}{|N|!} (v(S \cup \{i\}) - v(S)) \quad (4)$$

Keterangan :

$N$  = Set semua fitur

$S$  = Subset dari  $N$  yang tidak mengandung fitur  $i$

$v(S)$  = Fungsi nilai yang memberikan *output* model saat hanya fitur dalam  $S$  digunakan

## 3. METODE PENELITIAN

### 3.1 Sumber Data dan Variabel Penelitian

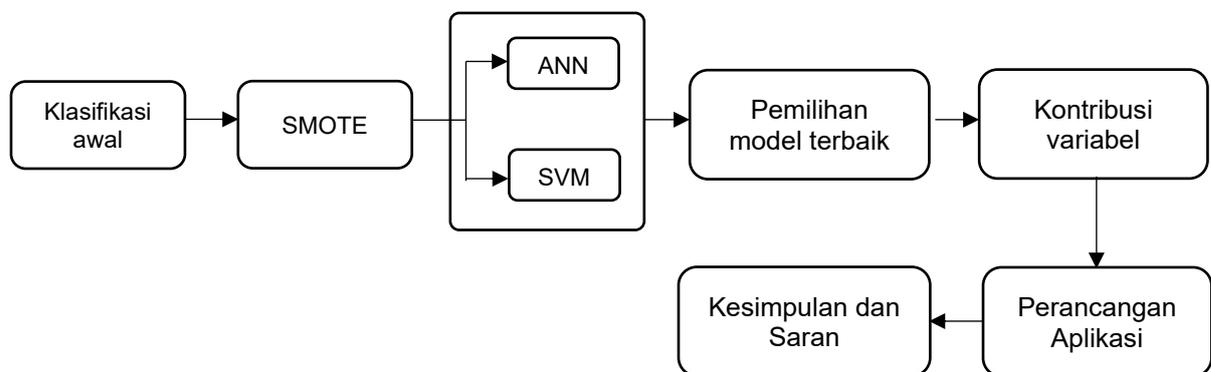
Data yang digunakan pada penelitian ini adalah data sekunder yang diperoleh dari laporan keuangan perusahaan teknologi yang terdaftar dan tercatat laporan keuangannya di Bursa Efek Indonesia (BEI) secara lengkap selama 2020-2023. Variabel penelitian yang digunakan dalam penelitian ini dibagi menjadi variabel respon dan prediktor di mana variabel prediktor merupakan rasio-rasio keuangan yang ditunjukkan sebagai berikut.

Variabel	Deskripsi	Skala Data
Y	Kondisi Keuangan 1 : <i>Financial Distress</i> 0 : <i>Non Financial Distress</i>	Nominal
A	<i>Return On Assets</i> (ROA)	Rasio
B	<i>Debt to Assets Ratio</i> (DAR)	Rasio
C	<i>Current Ratio</i>	Rasio

Variabel	Deskripsi	Skala Data
X1	Quick Ratio	Rasio
X2	Cash Ratio of Total Liabilities	Rasio
X3	Debt to Equity Ratio (DER)	Rasio
X4	Equity Multiplier	Rasio
X5	Return On Equity	Rasio
X6	Total Assets Turnover	Rasio
X7	Price Earning Ratio	Rasio
X8	Price Book Value	Rasio

### 3.2 Langkah Analisis

Langkah-langkah analisis dalam penelitian ini melibatkan beberapa tahap. *Flowchart* langkah analisis pada studi ini ditunjukkan pada Gambar 5 yang secara lebih rinci akan kami uraikan. Tahap pertama adalah persiapan data, yang mencakup perhitungan rasio keuangan perusahaan sektor teknologi di BEI dari tahun 2020 hingga 2023, klasifikasi awal perusahaan menggunakan model Zmijewski. Data kemudian dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian, dengan penggunaan metode SMOTE untuk menyeimbangkan data jika terdapat ketidakseimbangan. Setelah resampling, t-SNE digunakan untuk mereduksi dimensi dan memvisualisasikan data. Tahap kedua melibatkan analisis dengan metode ANN, termasuk penentuan jumlah neuron, bobot awal, dan bias, serta *fitting model* menggunakan data pelatihan. Tahap ketiga menggunakan SVM, di mana *hyperparameter tuning* dilakukan untuk RBF kernel sebelum *fitting model*. Tahap terakhir adalah evaluasi model, dengan validasi hasil klasifikasi menggunakan *confusion matrix*. Model terbaik dipilih berdasarkan akurasi dan F1 Score tertinggi antara SVM dan ANN. Penelitian diakhiri dengan pemeriksaan kontribusi variabel, perancangan aplikasi, serta penarikan kesimpulan dan saran.



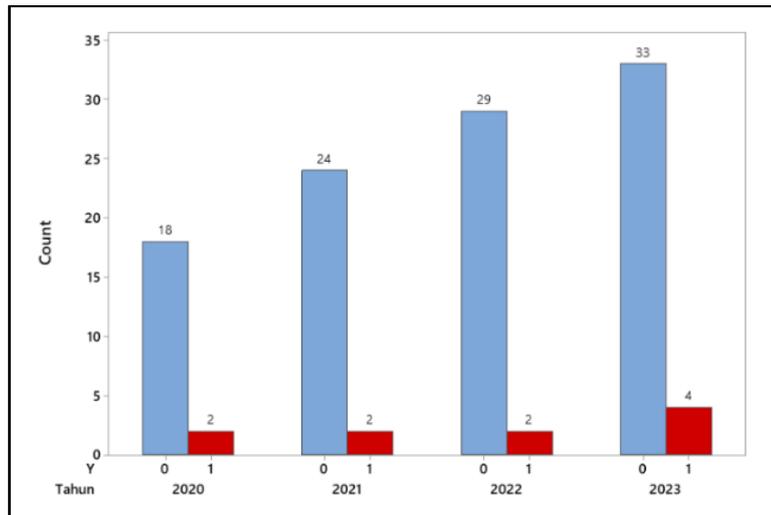
Gambar 5. Flowchart Analisis

## 4. HASIL DAN PEMBAHASAN

### 4.1 Karakteristik Financial Distress Perusahaan Sektor Teknologi

Karakteristik data perusahaan sektor teknologi di Indonesia sebanyak 39 perusahaan. Dalam beberapa tahun terakhir, sejumlah perusahaan teknologi baru telah melakukan *Initial Public Offering* (IPO), yang mengakibatkan jumlah perusahaan yang terdata menjadi lebih sedikit.

Berdasarkan Gambar 6, puncak jumlah perusahaan yang mengalami *financial distress* terjadi pada tahun 2023, dengan 4 perusahaan terdampak dan 33 perusahaan lainnya tidak. Pada tahun 2020 hingga 2022, masing-masing tercatat 2 perusahaan mengalami *financial distress*. Perusahaan seperti PT Anabatic Technologies (ATIC) dan PT Envy Technologies Indonesia (ENVY) menghadapi *financial distress* selama beberapa tahun, dengan tambahan perusahaan seperti PT Tourindo Guide Indonesia (PGJO) dan PT Gojek Tokopedia (GOTO) pada tahun 2023. Lonjakan kasus pada tahun 2023 disebabkan oleh kenaikan suku bunga, yang meningkatkan biaya pinjaman dan memberi tekanan pada kemampuan perusahaan untuk memenuhi kewajiban finansial mereka.



Gambar 5. Kondisi Keuangan Perusahaan Sektor Teknologi

#### 4.2 Pembagian Data Training dan Testing

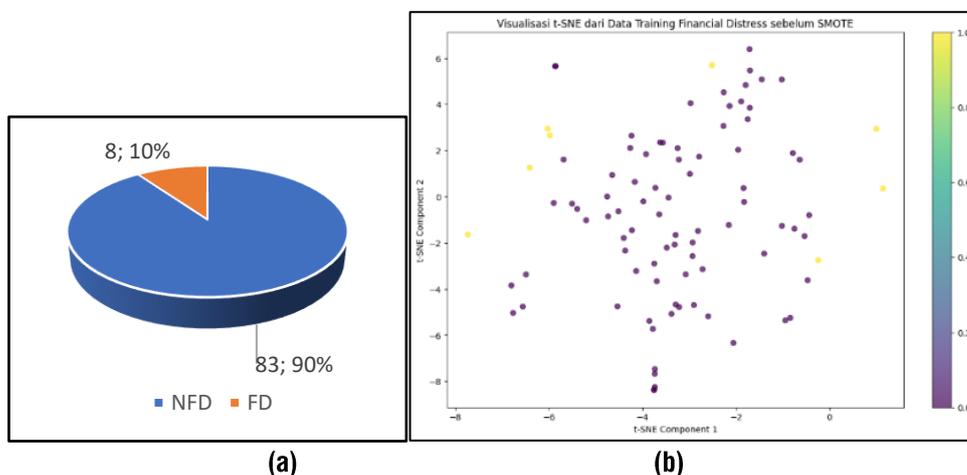
Pada tahap ini, data diklasifikasikan menjadi dua, yaitu *data training* dan *data testing*. Pembagian proporsi data *training* dan testing seperti tersaji pada Tabel 2. *Data training* digunakan untuk melatih algoritma sehingga didapatkan model, sedangkan *data testing* digunakan untuk menguji model yang telah didapatkan.

Tabel 2. Pembagian Data

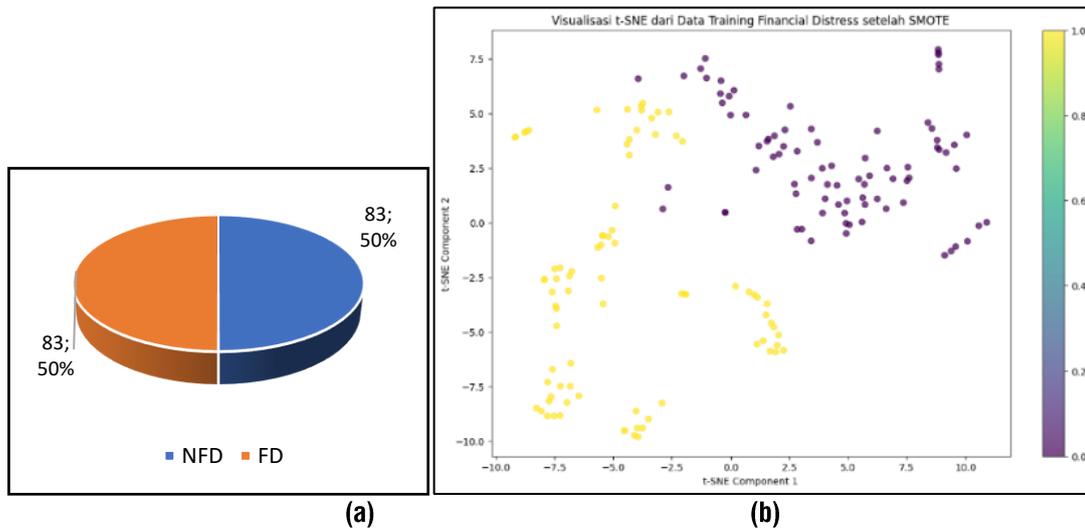
Keterangan	Training	Testing	Total
Jumlah	91	23	114
Persentase	80%	20%	100%

#### 4.3 Balancing Data

Data menunjukkan ketidakseimbangan kelas yang tinggi pada perusahaan teknologi. Untuk mengatasi ini, metode SMOTE digunakan untuk menyeimbangkan distribusi kelas. Visualisasi hasil resampling dilakukan dengan t-SNE untuk memahami struktur data secara lebih jelas. Dari Gambar 7 tersebut, terlihat bahwa ada ketidakseimbangan data yang jelas. Titik-titik berwarna kuning mewakili kelas minoritas (*distress*) tersebar di beberapa area, tetapi jumlahnya sangat sedikit dibandingkan dengan titik-titik berwarna ungu yang mewakili kelas mayoritas (*non distress*). Ketidakseimbangan ini menunjukkan bahwa sebelum dilakukan SMOTE, kelompok *distress* sangat kurang oleh karena itu proses SMOTE nantinya akan membuat data sintesis pada kelas minoritas, sehingga distribusi data lebih seimbang.



Gambar 7. (a) Jumlah Data Sebelum SMOTE, (b) Visualisasi dengan t-SNE



Gambar 8. (a) Jumlah Data Setelah SMOTE, (b) Visualisasi dengan t-SNE

Setelah penerapan SMOTE, distribusi titik kuning dan ungu menjadi lebih merata seperti terlihat pada Gambar 8, menunjukkan bahwa SMOTE berhasil menambah jumlah sampel kelas minoritas. Hal ini menunjukkan dua kelompok yang lebih jelas, menunjukkan adanya pemisahan yang lebih baik antar kelas. Penyebaran titik lebih merata, membuat data menjadi lebih seimbang.

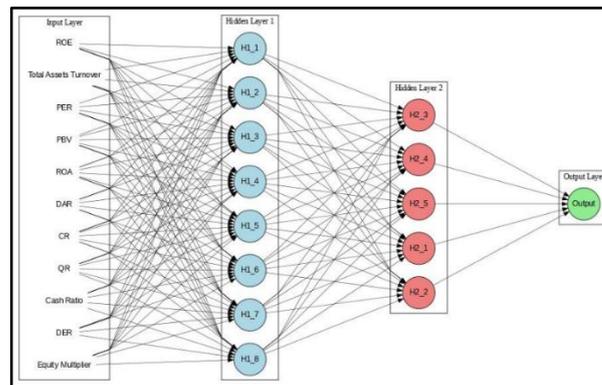
#### 4.4 Metode Artificial Neural Network

Salah satu metode yang efektif untuk memprediksi *financial distress* adalah melalui *Artificial Neural Network* (ANN). Dalam penelitian ini, arsitektur ANN yang diusulkan terdiri dari 1 input layer dengan 11 *neuron*, masing-masing mewakili 11 variabel prediktor atau rasio keuangan yang digunakan. Model ini juga memiliki 1 *output layer* dengan 1 *neuron*, yang menghasilkan klasifikasi biner, di mana *financial distress* (FD) diklasifikasikan sebagai 1 dan *non-financial distress* (NFD) sebagai 0. Dilakukan proses optimasi parameter dengan hasil kombinasi parameter ditunjukkan pada Tabel 3 berikut.

Tabel 3. Model ANN

Learning Rate	Hidden Neuron	Epochs	Train Accuracy	Test Accuracy	Sensitivity	Specificity	F1 Score
0,0001	[8, 5]	300	50%	8,70%	100%	0%	16%
0,0001	[8, 5]	500	50%	91,30%	0%	100%	0%
<b>0,0001</b>	<b>[8, 5]</b>	<b>800</b>	<b>87,95%</b>	<b>95,65%</b>	<b>100%</b>	<b>95,24%</b>	<b>80%</b>
0,0001	[5, 5]	300	50%	91,30%	0%	100%	0%
0,0001	[5, 5]	500	54,82%	21,74%	100%	14,29%	18,18%
0,0001	[5, 5]	800	62,65%	95,65%	50%	100%	66,67%
0,0001	[8]	300	52,41%	91,30%	0%	100%	0%
0,0001	[8]	500	84,94%	86,96%	0%	95,24%	0%
0,0001	[8]	800	88,55%	95,65%	50%	100%	66,67%
0,00001	[8, 5]	300	46,99%	86,96%	0%	95,24%	0%
0,00001	[8, 5]	500	62,05%	34,78%	100%	28,57%	21,05%
0,00001	[8, 5]	800	50%	91,30%	0%	100%	0%
0,00001	[5, 5]	300	50%	91,30%	0%	100%	0%
0,00001	[5, 5]	500	50%	8,70%	100%	0%	16%
0,00001	[5, 5]	800	49,40%	78,26%	0%	85,71%	0%
0,00001	[8]	300	57,23%	30,43%	100%	23,81%	20%
0,00001	[8]	500	50%	8,70%	100%	0%	16%
0,00001	[8]	800	58,43%	91,30%	50%	95,24%	50%

Kombinasi parameter model ANN terbaik seperti ditunjukkan pada Gambar 9 dengan melakukan penanganan pada ketidakseimbangan data menggunakan SMOTE adalah *learning rate* sebesar 0,0001, dengan 2 hidden size sebesar [8,5] dan jumlah *epoch* 800. Kombinasi parameter ini menghasilkan akurasi yang tinggi, terutama pada fase pengujian, serta *precision* yang sempurna. Meskipun *recall* dan *F1 score* menunjukkan variasi, secara keseluruhan, model ini dianggap optimal untuk data yang ada, menandakan bahwa struktur *hidden layers* dengan dua layer (8 dan 5 neuron) efektif dalam mengekstraksi pola dalam data dan meminimalkan kesalahan prediksi. Berikut visualisasi arsitektur model ANN terbaik.



Gambar 9. Arsitektur Model ANN Terbaik

#### 4.5 Metode Support Vector Machine

Selain metode ANN, salah satu metode yang digunakan dalam penelitian ini adalah metode *Support Vector Machine* (SVM). Oleh karena dalam penelitian sebelumnya menggunakan kernel Radial Basis Function (RBF), maka begitu pula pada penelitian ini. Kernel RBF merupakan salah satu kernel SVM yang paling populer dan kuat dalam klasifikasi dengan SVM. Analisis *financial distress* pada perusahaan teknologi dengan metode SVM dijelaskan pada Table 4 berikut.

Tabel 4. Model SVM

Kombinasi Parameter	Train Accuracy	Test Accuracy	Sensitivity	Specificity	F1 Score
$C = 0,25$ dan $\gamma = 0,01$	81,33%	91,30%	0%	100%	0%
$C = 0,25$ dan $\gamma = 1$	93,98%	78,26%	100%	76,19%	44,44%
$C = 0,5$ dan $\gamma = 0,01$	83,73%	91,30%	0%	100%	0%
$C = 0,5$ dan $\gamma = 1$	100%	82,61%	100%	80,95%	50%
<b><math>C = 1</math> dan <math>\gamma = 0,01</math></b>	<b>86,14%</b>	<b>95,65%</b>	<b>50%</b>	<b>100%</b>	<b>66,67%</b>
$C = 1$ dan $\gamma = 1$	100%	95,65%	50%	100%	66,67%

Kombinasi  $C = 1$  dan  $\gamma = 0,01$  memiliki performa terbaik di antara semua parameter yang diuji. Meskipun, hasilnya tidak jauh berbeda dengan  $C = 1$  dan  $\gamma = 1$ , terdapat indikasi bahwa model mungkin mengalami *overfitting*. Terlihat dari akurasi *training* yang lebih tinggi dibandingkan akurasi pada data *testing*, yang menunjukkan bahwa model cenderung menghafal data *training* dan kurang mampu melakukan generalisasi pada data baru.

#### 4.6 Perbandingan Hasil Prediksi Klasifikasi Metode ANN dan SVM

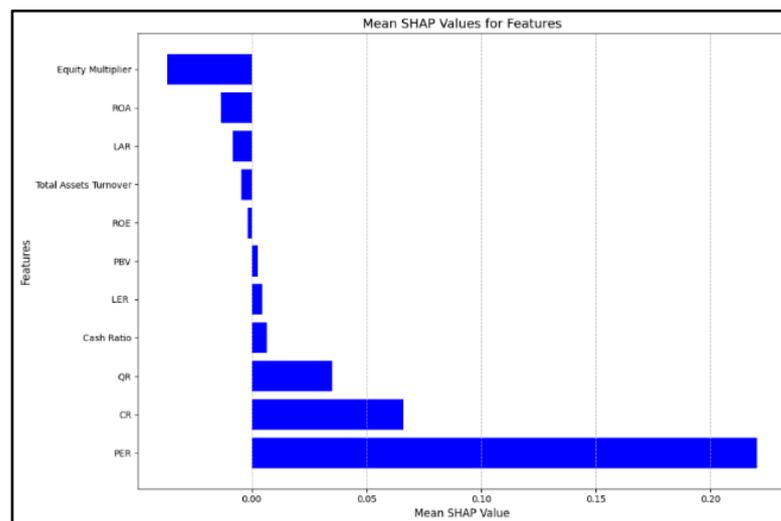
Penerapan SMOTE memberikan dampak positif dalam meningkatkan kemampuan model untuk menangani kelas *financial distress* yang lebih sedikit dalam data. Hasil evaluasi kedua metode dirangkum pada Tabel 5. Kedua model mencapai akurasi yang sama yaitu 95,65%, tetapi ANN memiliki sensitivitas yang lebih tinggi (100%) dibandingkan SVM (50%), yang berarti ANN berhasil mendeteksi semua kasus *financial distress*. Sementara itu, spesifisitas SVM lebih tinggi mencapai 100% menunjukkan kemampuannya dalam mengenali semua kasus *non-distress*, namun sensitivitas yang rendah yaitu hanya 50% membuatnya kurang efektif dalam mendeteksi *financial distress*. Sehingga, secara keseluruhan model ANN lebih andal dalam mendeteksi *financial distress* dibandingkan SVM pada perusahaan teknologi.

Tabel 5. Hasil Evaluasi Model ANN dan SVM

Metode	Akurasi	Sensitivitas	Spesifisitas	F1 Score
ANN	95,65%	100%	95,24%	80%
SVM	95,65%	50%	100%	66,67%

#### 4.7 Kontribusi Variabel Model Terbaik

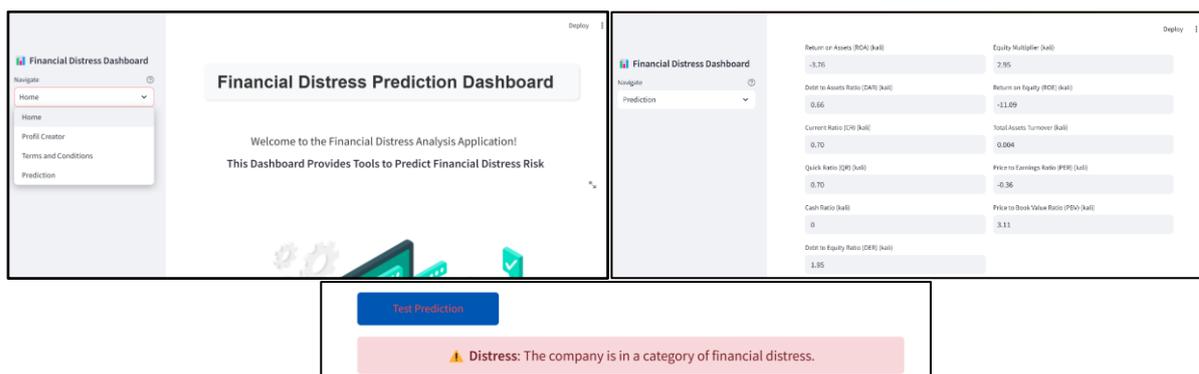
Hasil SHAP *Values* untuk model prediksi terbaik yaitu ANN MLP(11-8-5 -1). Pada Gambar 10 menunjukkan rata-rata nilai SHAP dari berbagai fitur input, mencerminkan pengaruh masing-masing fitur terhadap prediksi model. Setiap titik pada plot SHAP mewakili kontribusi satu perusahaan terhadap prediksi model. Titik di kanan menunjukkan pengaruh besar pada prediksi *financial distress*, sementara titik di kiri menunjukkan kecenderungan pada non-distress. Fitur dengan nilai SHAP tertinggi adalah PER (Price to Earnings Ratio), yang paling berkontribusi dalam prediksi model. PER normal berkisar antara 10-20, menunjukkan kinerja dan valuasi perusahaan yang baik. PER tinggi menunjukkan overvaluation, sedangkan PER rendah mengindikasikan undervaluation. PER negatif berarti perusahaan merugi. Di sisi lain, ROE (*Return on Equity*) memiliki kontribusi terendah, menunjukkan bahwa model kurang mempertimbangkan efisiensi penggunaan ekuitas dalam prediksi. Hal ini mungkin karena beberapa perusahaan dengan ROE tinggi tetap mengalami distress. Secara keseluruhan, perusahaan dengan kinerja keuangan baik memiliki PER moderat dan positif serta ROA tinggi.



Gambar 10. SHAP Values Model Terbaik

#### 4.8 Aplikasi Untuk Deteksi Dini Terjadinya Financial Distress

Penelitian ini menggunakan *framework* streamlit untuk menampilkan model dalam bentuk dashboard interaktif yang dapat diakses pada link yang terlampir berikut : <https://its.id/m/dashboardfinancialdistress> (ditunjukkan Gambar 11)



Gambar 11. *Framework* streamlit dalam tampilan web interaktif

## 5. KESIMPULAN

Berdasarkan hasil dan pembahasan, diperoleh beberapa kesimpulan. Pertama, terdapat peningkatan jumlah perusahaan yang mengalami *financial distress*, dengan puncaknya pada tahun 2023, di mana 4 perusahaan terdampak, dibandingkan dengan 2 perusahaan pada tahun-tahun sebelumnya. PT Anabatic Technologies (ATIC) dan PT Envy Technologies Indonesia (ENVY) konsisten menunjukkan kinerja buruk, terutama pada rasio *Debt to Equity* (DER) dan *Return on Equity* (ROE). Kedua, model prediksi *financial distress* dengan ANN unggul dalam menangkap pola data kompleks. Kombinasi parameter terbaik pada model ANN adalah *learning rate* sebesar 0,0001, dengan 2 hidden size sebesar [8,5] dan jumlah *epoch* 800, menunjukkan akurasi sebesar 95,65%, sensitivitas mencapai 100%, dan *F1 Score* yaitu 80%, serta memberikan prediksi yang lebih andal. Ketiga, variabel *Price to Earning Ratio* (PER) terbukti memiliki pengaruh besar dalam memprediksi *financial distress* pada sektor teknologi. Terakhir, aplikasi berbasis web menggunakan *framework Streamlit* berhasil menyajikan model prediksi melalui *dashboard* interaktif dengan empat menu utama, termasuk menu *Prediction* yang memungkinkan pengguna memasukkan data rasio keuangan untuk memprediksi kondisi *financial distress* perusahaan secara langsung. Pada penelitian selanjutnya, perlu dilakukan beberapa hal untuk peningkatan dan pengembangan antara lain, menambah variabel eksternal seperti sentiment pasar dan inflasi agar model prediksi lebih komprehensif, selain itu dapat melakukan eksplorasi pada algoritma *deep learning* lain seperti CNN dan LSTM.

## DAFTAR PUSTAKA

- [1] M. I. R. Avisena, "Tantangan Ekonomi Indonesia di 2024 Dinilai Lebih Tinggi," 14 Januari 2024.
- [2] Jumirin and Y. Lubis, "Pengaruh Biaya Operasional Terhadap Peningkatan Pendapatan Operasional Pada Pt. Pelabuhan Indonesia I (Persero) Cabang Belawan," *Jurnal Riset Akuntansi dan Bisnis*, vol. 18, pp. 162-177, 2018.
- [3] R. Binekasri, "GOTO Bukukan Rugi Rp 90 Triliun, Ternyata Ini Penyebabnya," 19 Maret 2024.
- [4] IPOTNEWS, "Financial Statements 1Q 2024 of ATIC," 2024. [Online]. Available: [https://www.ipotnews.com/ipotnews/newsDetail.php?jdl=Financial\\_Statements\\_1Q\\_2024\\_of\\_ATIC&news\\_id=443020&group\\_news=RESEARCHNEWS&taging\\_subtype=ATIC&name=&search=y\\_general&q=Financial%20Statements&halaman=1](https://www.ipotnews.com/ipotnews/newsDetail.php?jdl=Financial_Statements_1Q_2024_of_ATIC&news_id=443020&group_news=RESEARCHNEWS&taging_subtype=ATIC&name=&search=y_general&q=Financial%20Statements&halaman=1). [Accessed 17 Juli 2024].
- [5] M. Musa and N. Indrastiti, "Terancam Delisting, Begini Kinerja Keuangan Envy Technologies (ENVY) Tahun 2023," 08 April 2024.
- [6] IPOTNEWS, "Saham LMAS Berpotensi Delisting Usai 1,5 Tahun Digembok," 2024. [Online]. Available: [https://www.ipotnews.com/ipotnews/newsDetail.php?jdl=Saham\\_LMAS\\_Berpotensi\\_Delisting\\_Usai\\_1\\_5\\_Tahun\\_Digembok&news\\_id=437914&group\\_news=RESEARCHNEWS&taging\\_subtype=LMAS&name=&search=y\\_general&q=Limas%20Indonesia%20Makmur&halaman=1](https://www.ipotnews.com/ipotnews/newsDetail.php?jdl=Saham_LMAS_Berpotensi_Delisting_Usai_1_5_Tahun_Digembok&news_id=437914&group_news=RESEARCHNEWS&taging_subtype=LMAS&name=&search=y_general&q=Limas%20Indonesia%20Makmur&halaman=1). [Accessed 18 July 2024].
- [7] H. Hasnidar, T. S. P. Dipoadmodjo, A. M. Amin, H. Budiyantri and A. P. Aslam, "Analisis Financial Distress Pada Perusahaan Maskapai Penerbangan Yang Terdaftar Di Bursa Efek Indonesia Tahun 2018-2022," *Southeast Asia Journal of Business, Accounting, and Entrepreneurship*, vol. 2, no. 2, p. 2, 2024.
- [8] N. Aydin, N. Sahin, M. Deveci and D. Pamucar, "Prediction of financial distress of companies with artificial neural networks," *Machine Learning with Applications*, vol. 10, 2022.
- [9] S. I. Amalia, "Analisis Perbandingan Klasifikasi Financial Distress Perusahaan Menggunakan Support Vector Machine Dan Artificial Neural Network Pada Perusahaan Pertambangan 2017-2018," Jurusan Statistika, Fakultas Matematika Dan Ilmu Pengetahuan Alam, Universitas Islam Indonesia, Yogyakarta, 2017.
- [10] G. L. Silanno and L. G. Loupaty, "Pengaruh Current Ratio, Debt T Equity Ratio Dan Return on Asset Terhadap Financial Distress Pada Perusahaan-Perusahaan Di Sektor Industri Barang Konsumsi," *INTELEKTIVA : JURNAL EKONOMI, SOSIAL & HUMANIORA*, vol. 2, 2021.
- [11] M. E. Zmijewski, "Methodological Issues Related to the Estimation of Financial Distress Prediction Models," *Journal of Accounting Research*, vol. 22, pp. 59-82, 1984.
- [12] E. Ramdani, "Financial Distress Analysis Using The Zmijewski Method," *JIMFE (JURNAL ILMIAH MANAJEMEN FAKULTAS EKONOMI)*, vol. 6, 2020.

- N. Damayanti, "Klasifikasi Penyakit Paru Dengan Metode Artificial Neural Network (ANN) (Studi Kasus : RSUD Kertosono)," Departemen Sistem Informasi, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember, Surabaya, 2017.
- [13] A. S. Nugroho, A. B. Witarto and D. Handoko, "Support vector machine teori dan aplikasinya dalam bioinformatika," *Kuliah Umum IlmuKomputer. Com*, pp. 842-847, 2003.
- [14] N. V. Chawla, K. W. Bowyer, L. O. Hall and W. P. Kegelmeyer, "SMOTE: Synthetic Minority Over-sampling Technique," *Journal of Artificial Intelligence Research*, vol. 16, pp. 321-357, 2002.
- [15] A. A. Awan, "An Introduction to SHAP Values and Machine Learning Interpretability," 2023. [Online]. Available: <https://www.datacamp.com/tutorial/introduction-to-shap-values-machine-learning-interpretability>. [Accessed 30 July 2024].
- [16] I. R. Dewi, "GoTo-Shopee PHK, Ini Daftar Startup RI Bangkrut dan Tutup," 21 November 2022.
- [17]