

PREDIKSI POTENSI KEBANGKRUTAN PADA PERUSAHAAN YANG TERDAFTAR DI BEI MENGGUNAKAN ALGORITMA BACKPROPAGATION NEURAL NETWORK

I Nyoman Dita Suardinata, Nengah Widya Utami, Helmy Syakh Alam

Program Studi Sistem Informasi Akuntansi, Fakultas Teknologi Informasi dan Desain, Universitas Primakara
Jalan Tukad Badung No. 135 Renon, Denpasar. Bali, Indonesia
ditasuardinata10@gmail.com

ABSTRAK

Kebangkrutan merupakan kondisi dimana perusahaan mengalami kesulitan keuangan yang menyebabkan gagalnya suatu perusahaan dalam menjalankan operasionalnya dan ketidakmampuan membayar berbagai kewajiban yang dimiliki. Perusahaan yang bangkrut dapat merugikan pihak-pihak yang memiliki kepentingan seperti investor dan kreditor. Penelitian ini bertujuan untuk mengetahui berapa banyak perusahaan yang terdaftar pada BEI yang berpotensi mengalami kebangkrutan. Backpropagation Neural Network adalah salah satu metode jaringan syaraf tiruan yang digunakan dalam memprediksi kebangkrutan. Dalam penelitian ini, backpropagation yang digunakan untuk memprediksi kebangkrutan yang digabungkan dengan rasio keuangan sebagai atribut input, dan hasil dari perhitungan Model Grover akan menjadi target output. Hasil dari penelitian ini menghasilkan nilai MSE terendah di angka 0,004 dengan tingkat akurasi sebesar 99,06%. Angka ini diperoleh menggunakan split validation 60:40, laju pembelajaran sebesar 0,2, jumlah neuron pada hidden layer sebesar 2 neuron, nilai bias dan bobot sebesar 3,1, jumlah iterasi sebanyak 5925. Perusahaan yang diprediksi berpotensi mengalami kebangkrutan sebanyak 134 perusahaan dan Perusahaan yang diprediksi tidak mengalami kebangkrutan adalah 666 perusahaan.

Kata kunci: Prediksi Kebangkrutan, Model Grover, Backpropagation Neural Network, Rasio Keuangan.

1. PENDAHULUAN

Pada Maret tahun 2020 pandemi Covid-19 hadir di Indonesia yang menyebabkan turunnya perekonomian Indonesia. Berdasarkan dari data Badan Pusat Statistik, Indonesia mengalami penurunan ekonomi pada tahun 2020 sebesar 2,07 persen [1]. Turunnya ekonomi di Indonesia ini terjadi karena adanya kebijakan yang dilakukan oleh pemerintah Indonesia untuk memutus penyebaran virus Covid-19 agar tidak semakin parah. Adapun kebijakan tersebut yaitu dengan menerapkan pemberlakuan pembatasan kegiatan masyarakat (PPKM), namun konsekuensi dari kebijakan ini adalah menurunnya aktivitas perekonomian dalam masyarakat yang berimbas kepada turunnya kinerja di berbagai sektor usaha yang diukur berdasarkan nilai kapitalisasi pasar.

Pada tahun 2020, delapan dari sebelas sektor usaha mengalami penurunan kinerja dibandingkan dengan tahun 2019 dan ada tiga sektor yang menunjukkan kinerja yang positif. Jika melihat data kinerja di tahun 2021 kinerja kebanyakan sektor usaha sudah mulai meningkat dan hanya ada dua sektor yang masih mengalami penurunan. Pada tahun 2022, lima sektor usaha mengalami peningkatan kinerja, tetapi ada sektor usaha yang sebelumnya sudah mulai menunjukkan kinerja yang positif di tahun sebelumnya malah mengalami penurunan kinerja di tahun 2022. Data dari Bursa Efek Indonesia tahun 2022 menunjukkan ada 8 perusahaan yang masuk dalam notasi khusus dengan kode S yang berarti laporan keuangan terakhir menunjukkan tidak menghasilkan pendapatan dan ada 49 yang masuk dalam notasi khusus dengan kode E yang berarti Laporan keuangan terakhir menunjukkan ekuitas negatif ekuitas

berdasarkan laporan keuangan terakhir [2]. Ini menunjukkan bahwa masih ada perusahaan yang berada pada sektor-sektor tersebut belum sepenuhnya bangkit dari dampak pandemi Covid-19.

Jika kinerja suatu perusahaan terus menurun, maka perusahaan tersebut akan mengalami kesulitan keuangan. Dan jika suatu perusahaan dibiarkan dan kondisi bisnisnya memburuk, maka perusahaan tersebut akan mengalami kebangkrut. Kebangkrutan merupakan kondisi dimana perusahaan mengalami kesulitan keuangan yang menyebabkan gagalnya suatu perusahaan dalam menjalankan operasionalnya dan ketidakmampuan membayar kewajiban yang dimiliki [3]. Perusahaan yang bangkrut akan dapat berdampak pada pihak-pihak yang memiliki kepentingan seperti investor dan kreditor. Oleh karena itu, prediksi kebangkrutan bisa berperan sebagai peringatan awal bagi pihak yang memiliki kepentingan.

Penelitian mengenai prediksi kebangkrutan sudah pernah beberapa kali dilakukan. Salah satu cara yang digunakan untuk memprediksi kebangkrutan adalah menggunakan algoritma *Backpropagation Neural Network* yang digabungkan dengan rasio keuangan sebagai atribut atau parameter inputnya. Algoritma ini digunakan pada penelitian Rizki Amalia Nurdini (2019) dengan judul “Analisis Prediksi Kebangkrutan Perusahaan Menggunakan *Artificial Neural Network* Pada Sektor Pertambangan Batubara” menghasilkan kinerja pelatihan dengan MSE terendah 0,00000313 dan R tertinggi 99,9% [4].

Berdasarkan pada latar belakang yang telah dijelaskan diatas, penulis tertarik untuk melakukan penelitian dengan judul “Prediksi Potensi Kebangkrutan Pada Perusahaan yang Terdaftar pada

BEI Menggunakan Algoritma Backpropagation Neural Network”.

2. TINJAUAN PUSTAKA

2.1. Kebangkrutan

Kebangkrutan merupakan kondisi dimana perusahaan mengalami kesulitan keuangan yang menyebabkan gagalnya suatu perusahaan dalam menjalankan operasionalnya dan ketidakmampuan membayar berbagai kewajiban yang dimiliki. Terdapat dua aktor-faktor yang menyebabkan terjadinya kebangkrutan pada perusahaan, yaitu faktor internal dan eksternal [3].

Faktor internal yang dapat menyebabkan kebangkrutan adalah manajemen yang tidak efisien, terlalu banyak memberikan kredit pada pelanggan, dan kecurangan yang dilakukan manajemen perusahaan. Sedangkan, faktor eksternal bisa berasal dari persaingan, perubahan kebijakan pemerintah, dan krisis global.

2.2. Data Mining

Data mining merupakan ekstraksi data dalam jumlah yang besar menjadi suatu informasi atau pengetahuan yang bermanfaat [5]. *Data mining* juga dapat diartikan sebagai proses pengolahan data untuk menggali suatu informasi dalam data yang digunakan. Proses penggalian data ini sering disebut juga dengan *Knowledge Discovery in Databases* (KDD).


2.3. Backpropagation Neural Network

Backpropagation Neural Network (BPNN) adalah sebuah jenis jaringan syaraf tiruan yang termasuk dalam *supervised learning* dengan menggunakan *multilayer perceptron*. Jaringan ini memiliki dua arah, yaitu maju (*forward*) dan mundur (*backward*). Arsitektur BPNN terdiri dari tiga layer utama, yaitu *input layer*, *hidden layer*, dan *output layer* [6].

Proses pembelajaran pada BPNN dilakukan dengan melakukan propagasi maju (*forward propagation*) untuk menghitung output dari jaringan berdasarkan input data, dan kemudian melakukan propagasi mundur (*backward propagation*) untuk menyesuaikan bobot pada setiap layer agar prediksi output semakin mendekati nilai target yang diinginkan [6].

3. METODE PENELITIAN

Penelitian ini akan menggunakan metode *Knowledge Discovery in Databases* (KDD) atau Penemuan Pengetahuan dalam Basis Data. KDD merupakan sebuah proses untuk menemukan informasi penting, pola dan hubungan dalam data dengan menggunakan algoritma dalam membantu mengidentifikasi pola dalam data [5]. KDD memiliki enam langkah dalam memproses data mentah menjadi informasi yang berguna. Langkah-langkah yang ada dalam KDD ditunjukkan pada gambar berikut:



Gambar 1. Proses *Knowledge Discovery in Databases*

3.1. Data Selection

Pada tahap *data selection*, peneliti melakukan seleksi atribut-atribut data yang dianggap relevan dengan rumusan masalah pada laporan keuangan perusahaan. Data dalam penelitian ini ada 4 atribut, yaitu ROA, WCTA, ROTA, dan CR.

3.2. Data Cleaning

Pada tahap *data cleaning*, akan dilakukan evaluasi terhadap kualitas data. Data yang tidak memiliki nilai akan dibuang atau tidak digunakan dalam dataset.

3.3. Data Transformation

Pada tahapan ini, dilakukan perubahan status perusahaan menjadi numerik. Ini dilakukan karena setiap proses pada algoritma *Backpropagation Neural Network* memerlukan *input* numerik dan menghasilkan *output* numerik.

3.4. Data mining

Tahap ini adalah tahap utama dalam penelitian ini, dimana peneliti akan mencari pengetahuan atau pola dalam data yang telah dikumpulkan menggunakan algoritma *Backpropagation Neural Network*.

3.5. Interpretation dan Evaluation

Tahap Interpretation dan evaluation merupakan tahap interpretasi data dengan menggunakan aplikasi data mining. Pengujian data dan evaluasi hasil pengujian dalam penelitian ini menggunakan Python. Pada tahap *evaluation*, tahap di mana penulis memprediksi potensi kebangkrutan menggunakan algoritma *Backpropagation Neural Network*. Pada penelitian ini, model dievaluasi dengan menggunakan metrik *Mean Square Error* (MSE).

3.6. Knowledge

Knowledge merupakan tahap dimana data telah diolah dan sudah menghasilkan pengetahuan atau informasi yang bermanfaat dan mudah dipahami. Pengetahuan dan informasi diperoleh kemudian akan yang diimplementasikan sesuai dengan kegunaan pengetahuan atau informasi tersebut.

3.7. Metode Analisis Rasio Keuangan

Rasio keuangan yang digunakan pada penelitian ini adalah *return on asset* (ROA), *Working Capital to Total Assets ratio*, dan *Return on total assets* (ROTA). Rasio ini penulis pilih karena menurut Grover, ketiga rasio ini merupakan rasio yang paling berpengaruh dari tiga belas rasio yang telah diteliti [7]. Peneliti juga menambahkan *Current Ratio* karena menurut penelitian Dwi Fitrianiingsih, rasio lancar memiliki pengaruh yang signifikan terhadap kebangkrutan perusahaan [8].

a. *Return on asset* (ROA)

Return on asset (ROA) memberikan informasi tentang seberapa efisien perusahaan dalam menggunakan asetnya untuk menghasilkan laba [9]. Untuk menghitung ROA dapat menggunakan persamaan (1):

$$ROA = \frac{\text{Net Profit}}{\text{Total Assets}} \quad (1)$$

b. *Working Capital to Total Assets* (WCTA)

Working Capital to Total Asset merupakan salah satu rasio likuiditas yang menunjukkan kemampuan perusahaan dalam menggunakan modal kerja untuk menjalankan kegiatan operasional tanpa mengganggu tingkat likuiditas perusahaan [10]. Untuk menghitung WCTA dapat menggunakan persamaan (2):

$$WCTA = \frac{(\text{Current Asset} - \text{Current Liabilities})}{\text{Total Assets}} \quad (2)$$

c. *Return on total assets* (ROTA)

Return on total assets (ROTA) adalah rasio yang mengukur laba perusahaan sebelum bunga dan pajak (EBIT) terhadap total aset [11]. Untuk menghitung ROTA dapat menggunakan persamaan (3):

$$ROTA = \frac{\text{EBIT}}{\text{Total Assets}} \times 100\% \quad (3)$$

d. *Current Ratio* (CR)

Current ratio merupakan suatu metrik keuangan yang digunakan untuk mengevaluasi kemampuan sebuah perusahaan dalam memenuhi kewajiban finansialnya yang jatuh tempo dalam jangka waktu pendek, biasanya dalam satu tahun. Rasio ini dihitung dengan membandingkan total aset lancar (atau aset yang dapat dengan cepat diubah menjadi uang tunai) dengan total kewajiban jatuh tempo. [11]. Untuk menghitung CR dapat menggunakan persamaan (4):

$$CR = \frac{\text{Current Asset}}{\text{Current Liabilities}} \times 100\% \quad (4)$$

3.8. Backpropagation Neural Network

Backpropagation Neural Network (BPNN) adalah sebuah jenis jaringan syaraf tiruan yang termasuk dalam *supervised learning* dengan menggunakan *multilayer perceptron*. Jaringan ini memiliki dua arah, yaitu maju (*forward*) dan mundur (*backward*). *supervised learning* ini adalah teknik yang memanfaatkan data yang telah dipelajari pada masa lalu untuk memprediksi peristiwa di masa yang akan datang [6]. Langkah pembelajaran dalam algoritma

backpropagation neural network adalah sebagai berikut:

- Inisialisasi bobot, tentukan *learning rate* (α), maksimum *epoch*, dan target *error* untuk menentukan kapan model akan berhenti.
- Tiap unit pada lapisan *input* menerima sinyal *input* x_i dan meneruskan sinyal tersebut ke semua unit pada lapisan tersembunyi.
- Tiap-tiap unit pada lapisan tersembunyi menjumlahkan sinyal-sinyal *input* terbobot menggunakan persamaan (5):

$$z_{in_j} = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (5)$$

Kemudian dihitung nilai *output* dengan menggunakan fungsi aktivasi seperti persamaan ini (6):

$$z_j = \frac{1}{(1+e^{-z_{in_j}})} \quad (6)$$

- Tiap-tiap unit pada lapisan *output*, jumlahkan bobotnya dengan sinyal *input* masing-masing dengan menggunakan persamaan (7):

$$y_{in_k} = w_{0k} + \sum_{j=1}^p z_j w_{jk} \quad (7)$$

- Tiap-tiap unit *output* y_k , menerima target pola yang berhubungan dengan pola *input* pembelajaran, hitung informasi *error* menggunakan persamaan (8):

$$\delta_k = (t_k - y_k) f'(y_{in_k}) \quad (8)$$

Kemudian hitung perubahan nilai bobot yang kemudian digunakan untuk memperbaharui nilai w_{jk} menggunakan persamaan (9):

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (9)$$

Hitung perubahan nilai bias yang kemudian digunakan untuk memperbaharui nilai w_{0k} menggunakan persamaan (10):

$$\Delta w_{0k} = \alpha \delta_k \quad (10)$$

- Tiap-tiap unit *hidden layer* menjumlahkan delta *input* (dari unit-unit yang berada pada lapisan sesudahnya) menggunakan persamaan (11):

$$\delta_{in_j} = \sum_{k=1}^m \delta_k w_{jk} \quad (11)$$

Kemudian hasil tersebut dikalikan dengan nilai turunan dari fungsi aktivasi untuk menghitung informasi kesalahan menggunakan persamaan (12).

$$\delta_j = \delta_{in_j} f'(z_{in_j}) \quad (12)$$

Hitung perubahan nilai bobot yang kemudian digunakan untuk memperbaharui v_{ij} menggunakan persamaan (13):

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (13)$$

Hitung juga perubahan bias (yang nantinya digunakan untuk memperbaiki nilai v_{0j}) menggunakan persamaan (14):

$$\Delta v_{0j} = \alpha \delta_j \quad (14)$$

- g. Tiap-tiap unit *output* dilakukan pembaruan bobot dan bias menggunakan persamaan (15) untuk bobot dan persamaan (16) untuk bias, sebagai berikut :

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (15)$$

$$w_{0k}(\text{baru}) = w_{0k}(\text{lama}) + \Delta w_{0k} \quad (16)$$

Tiap-tiap unit *hidden* z_j juga dilakukan pembaruan bobot dan biasnya menggunakan persamaan (17) untuk bobot dan persamaan (18) untuk bias :

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (17)$$

$$v_{0j}(\text{baru}) = v_{0j}(\text{lama}) + \Delta v_{0j} \quad (18)$$

- h. Menguji apakah kondisi penghentian sudah tercapai. Jika belum, maka ulangi langkah ke-2 sampai 7 hingga mencapai kondisi penghentian.

4. HASIL DAN PEMBAHASAN

4.1. Data Selection

Data yang digunakan dalam penelitian ini merupakan data laporan keuangan perusahaan tahun 2022 yang diambil dari website Bursa Efek Indonesia, dimana berupa data mentah dalam bentuk file Pdf. Data yang digunakan yaitu data hasil perhitungan rasio dari laporan keuangan perusahaan sebanyak 800 data. Sub laporan keuangan yang digunakan adalah, Laporan Posisi Keuangan dan Laporan Laba Rugi Tahunan Perusahaan. Pada tahap seleksi data, dilakukan perhitungan rasio-rasio keuangan dan dilanjutkan dengan penentuan label menggunakan model Grover. Rasio keuangan yang digunakan yaitu *Return on Asset Ratio* (ROA), *Working Capital to Total Asset Ratio* (WCTA), *Return on Total Asset* (ROTA), dan *Current Ratio* (CR) sebelum dilakukannya tahapan preprocessing atau cleaning. Adapun dataset rasio keuangan perusahaan ditampilkan sebagai berikut:

Tabel 1. Dataset Rasio Keuangan Perusahaan

No	ROA	WCTA	ROTA	CR	Status
1	0,75	0,18	0,08	3,60	Tidak Bangkrut
2	-0,08	0,03	-0,08	1,08	Berpotensi Bangkrut
3	0,04	0,69	0,05	213	Tidak Bangkrut
4	0,17	0,05	0,22	1,15	Tidak Bangkrut
...					
800	0,005	0,18	-0,01	1,44	Tidak Bangkrut

Tabel diatas menunjukkan data hasil perhitungan rasio keuangan perusahaan yang telah dihitung dari Laporan Posisi Keuangan dan Laporan Laba Rugi

Perusahaan. Data ini akan melalui beberapa tahapan untuk dapat diproses ke tahapan pengujian menggunakan Google Colabatory.

4.2. Data Cleaning

Pada tahap *data preprocessing* atau *cleaning*, akan dilakukan evaluasi terhadap kualitas data. Data yang tidak memiliki nilai (*missing value*) akan dibuang atau tidak digunakan dalam dataset. Pada 800 dataset yang digunakan, tidak ada data yang tidak memiliki nilai atau *missing value*.

4.3. Data Transformation

Data Transformasi merupakan fase dimana data melewati fase seleksi dan fase pembersihan. Pada tahap ini, data yang ada harus disesuaikan dengan algoritma proses data mining. Pada tahapan ini, dilakukan pengubah status perusahaan menjadi numerik.

Tabel 2. Data setelah tahap Transformation

No	ROA	WCTA	ROTA	CR	Status
1	0,75	0,18	0,08	3,60	0
2	-0,08	0,03	-0,08	1,08	1
3	0,04	0,69	0,05	213	0
4	0,17	0,05	0,22	1,15	0
...					
800	0,005	0,18	-0,01	1,44	0

Tabel diatas menunjukkan data hasil tahap Transformation. Kolom status yang sebelumnya berisi teks diubah menjadi numerik sebelum masuk tahap pengujian.

4.4. Data Mining

Proses selanjutnya setelah transformation adalah *data mining*, dimana proses ini merupakan proses dimana peneliti menentukan dan mengimplementasikan metode atau algoritma yang akan digunakan dalam menganalisa data. Penelitian ini menggunakan metode *Backpropagation Neural Network* dengan bahasa pemrograman python yang dioperasikan dalam *notebook* Google Colabatory. Berikut langkah-langkah implementasi menggunakan Google Colabatory:

- Import data ke notebook
Untuk proses *import* data ke notebook menggunakan bantuan dari *library* Pandas.
- Membagi data training dan testing
Pada penelitian ini data akan dibagi menjadi data *training* sebesar 60% dan data *testing* sebanyak 40%.
- Menentukan parameter jaringan
Parameter jaringan yang digunakan dalam penelitian ini adalah *learning rate* dengan nilai 0,5, jumlah *iteration* sebanyak 10.000 , *neuron input layer* sebanyak 4 *neuron*, 3 *neuron hidden layer*, dan *output layer* sebanyak 1 *neuron*, serta nilai bias dan bobot masing masing 0,2.

- d. Proses *Feedforward* dan *Backpropagation*
Proses *Feedforward* dilakukan untuk menghitung output dari jaringan berdasarkan input data, dan kemudian melakukan propagasi mundur (*backward propagation*) untuk menyesuaikan bobot pada setiap layer agar prediksi output semakin mendekati nilai target yang diinginkan.
- e. Menghitung perubahan bobot dan bias
Menghitung perubahan bobot dan bias dilakukan untuk mengoptimalkan model sehingga dapat melakukan prediksi yang lebih akurat pada data yang belum pernah dilihat sebelumnya (*data testing*).
- f. Menguji model dengan data *testing*
Pengujian model yang sudah dilatih menggunakan data *testing* dilakukan dengan proses propagasi maju.
- g. Menghitung Akurasi data *testing*
Menghitung tingkat akurasi dan tingkat rata-rata kesalahan.

4.5. Interpretation dan Evaluation

Selanjutnya merupakan hasil evaluasi pada algoritma *backpropagation neural network*. Pada tahap ini peneliti melakukan pengujian untuk memperoleh hasil nilai MSE terbaik yang dilakukan dengan empat cara. Diantaranya, mengubah laju pembelajaran (*learning rate*), mengubah jumlah *neuron* pada lapisan tersembunyi (*hidden layer*), mengubah nilai bias dan bobot, dan membagi jumlah dataset (*split validation*).

4.5.1. Pengujian Laju Pembelajaran (*Learning Rate*)

Pada pengujian pertama, parameter laju pembelajaran yang digunakan adalah 0,1 sampai 0,5. Selanjutnya parameter lain yang digunakan, yaitu 10.000 iterasi, 3 *neuron* pada *hidden layer*, nilai bias dan bobot sebesar 0,2, dan pembagian data sebesar 60:40. Tabel 3 merupakan hasil dari pengujian yang telah dilakukan yang menampilkan nilai MSE terbaik yang diperoleh pada rentang iterasi 10.000.

Tabel 3. Hasil Pengujian Laju Pembelajaran

Laju Pembelajaran	Nilai MSE	
	Data Latih	Data Uji
1	0,0311 (Iterasi 10000)	0,0372 (Iterasi 10000)
2	0,0278 (Iterasi 10000)	0,0333 (Iterasi 10000)
3	0,0937 (Iterasi 10000)	0,0875 (Iterasi 10000)
4	0,0937 (Iterasi 10000)	0,0875 (Iterasi 10000)
5	0,0937 (Iterasi 10000)	0,0875 (Iterasi 10000)

Berdasarkan Tabel 3, dapat diketahui jika nilai laju pembelajaran dapat mempengaruhi nilai MSE yang dihasilkan jaringan. Dalam pengujian ini, laju

pembelajaran terbaik didapatkan pada nilai 0,2 dengan nilai MSE paling rendah diantara laju pembelajaran yang lainnya sebesar 0,0278 (Iterasi 10000) pada data latih dan 0,0333 (Iterasi 10000) pada data uji.

4.5.2. Pengujian Jumlah *Neuron* pada *Hidden Layer*

Pengujian jumlah *neuron* pada *hidden layer* dilakukan menggunakan 2 sampai 6 *neuron*, jumlah *hidden layer* ini sesuai dengan aturan dari Jeff Heaton mengenai jumlah *neuron* pada *hidden layer*. Parameter lain yang digunakan 10.000 iterasi, laju pembelajaran sebesar 0,2, nilai bias dan bobot sebesar 0,2, dan pembagian data sebesar 60:40. Tabel 4 merupakan hasil dari pengujian yang telah dilakukan yang menampilkan nilai MSE terbaik yang diperoleh pada rentang iterasi 10.000.

Tabel 4. Hasil Pengujian Jumlah *Neuron Hidden Layer*

Jumlah <i>Neuron</i>	Nilai MSE	
	Data Latih	Data Uji
2	0,0263 (Iterasi 10000)	0,0278 (Iterasi 10000)
3	0,0278 (Iterasi 10000)	0,0333 (Iterasi 10000)
4	0,0297 (Iterasi 10000)	0,0364 (Iterasi 10000)
5	0,0314 (Iterasi 10000)	0,0366 (Iterasi 2691)
6	0,0328 (Iterasi 10000)	0,0371 (Iterasi 3027)

Berdasarkan Tabel 4, dapat diketahui jika jumlah *neuron* pada *hidden layer* dapat mempengaruhi nilai MSE yang dihasilkan jaringan. Dalam pengujian ini, jumlah *neuron hidden layer* terbaik diperoleh pada 2 *neuron* dengan nilai MSE yang paling rendah pada data latih dan data uji di 0,0263 (Iterasi 10.000) pada data latih dan 0,0278 (Iterasi 10.000) pada data uji.

4.5.3. Pengujian Nilai Bias dan Bobot

Pengujian nilai bias dan bobot dilakukan menggunakan nilai 0,1 sampai 4. Parameter lain yang digunakan 10.000 iterasi, laju pembelajaran sebesar 0,2, 2 *neuron* pada *hidden layer* dan pembagian data sebesar 60:40. Tabel 5 merupakan hasil dari pengujian yang telah dilakukan yang menampilkan nilai MSE terbaik yang diperoleh pada rentang iterasi 10.000.

Tabel 5. Hasil Pengujian Nilai Bias dan Bobot

Jumlah <i>Neuron</i>	Nilai MSE	
	Data Latih	Data Uji
0,1	0,0262 (Iterasi 10000)	0,0273 (Iterasi 10000)
0,2	0,0263 (Iterasi 10000)	0,0278 (Iterasi 10000)
0,3	0,0264 (Iterasi 10000)	0,0281 (Iterasi 10000)
0,4	0,0263 (Iterasi 10000)	0,0277 (Iterasi 10000)
0,5	0,0261	0,0266

Jumlah Neuron	Nilai MSE	
	Data Latih	Data Uji
	(Iterasi 10000)	(Iterasi 10000)
0,6	0,0260 (Iterasi 10000)	0,0260 (Iterasi 10000)
0,7	0,0260 (Iterasi 10000)	0,0259 (Iterasi 10000)
0,8	0,0260 (Iterasi 10000)	0,0260 (Iterasi 10000)
0,9	0,0260 (Iterasi 10000)	0,0260 (Iterasi 10000)
1	0,0260 (Iterasi 10000)	0,0261 (Iterasi 10000)
1,1	0,0259 (Iterasi 10000)	0,0281 (Iterasi 10000)
1,2	0,0198 (Iterasi 4830)	0,0221 (Iterasi 4716)
1,3	0,0158 (Iterasi 4216)	0,0171 (Iterasi 4183)
1,4	0,0133 (Iterasi 4352)	0,0142 (Iterasi 4007)
1,5	0,0116 (Iterasi 4821)	0,0120 (Iterasi 4526)
1,6	0,0106 (Iterasi 4474)	0,0106 (Iterasi 4409)
1,7	0,0097 (Iterasi 4624)	0,0094 (Iterasi 4496)
1,8	0,0089 (Iterasi 4781)	0,0085 (Iterasi 4704)
1,9	0,0084 (Iterasi 4999)	0,0078 (Iterasi 4768)
2	0,0080 (Iterasi 5227)	0,0072 (Iterasi 4907)
2,1	0,0075 (Iterasi 5447)	0,0065 (Iterasi 5000)
2,2	0,0071 (Iterasi 5858)	0,0059 (Iterasi 5405)
2,3	0,0068 (Iterasi 5963)	0,0055 (Iterasi 5383)
2,4	0,0066 (Iterasi 6185)	0,0050 (Iterasi 5539)
2,5	0,0064 (Iterasi 6409)	0,0047 (Iterasi 5755)
2,6	0,0063 (Iterasi 6636)	0,0044 (Iterasi 5826)
2,7	0,0062 (Iterasi 6733)	0,0042 (Iterasi 5941)
2,8	0,0061 (Iterasi 6700)	0,0042 (Iterasi 5913)
2,9	0,0061 (Iterasi 6611)	0,0041 (Iterasi 5877)
3	0,0061 (Iterasi 6749)	0,0041 (Iterasi 6027)
3,1	0,0061 (Iterasi 6620)	0,0040 (Iterasi 5925)
3,2	0,0269 (Iterasi 10000)	0,0269 (Iterasi 10000)
3,3	0,0062 (Iterasi 6886)	0,0062 (Iterasi 6886)
3,4	0,0281 (Iterasi 10000)	0,0338 (Iterasi 10000)
3,5	0,0291 (Iterasi 4118)	0,0335 (Iterasi 4021)
3,6	0,0286 (Iterasi 5889)	0,0332 (Iterasi 5894)

Jumlah Neuron	Nilai MSE	
	Data Latih	Data Uji
3,7	0,0282 (Iterasi 8576)	0,0328 (Iterasi 8656)
3,8	0,4062 (Iterasi 10000)	0,4125 (Iterasi 10000)
3,9	0,4062 (Iterasi 10000)	0,4125 (Iterasi 10000)
4	0,4062 (Iterasi 10000)	0,4125 (Iterasi 10000)

Berdasarkan Tabel 5, dapat diketahui nilai bias dan bobot dapat mempengaruhi nilai MSE yang dihasilkan jaringan. Dalam pengujian ini, nilai bias dan bobot terbaik diperoleh pada nilai 3,1 dengan MSE yang paling rendah pada data latih dan data uji di 0,0061 (Iterasi 6.620) pada data latih dan 0,0040 (Iterasi 5.925) pada data uji.

4.5.4. Pengujian Pembagian Jumlah Dataset (*split validation*)

Dalam pengujian ini dataset akan dibagi menjadi data latih dan data uji dengan rasio 60:40, 70:30, 80:20, dan 90:10. Parameter lain yang digunakan 10.000 iterasi, laju pembelajaran sebesar 0,2, 2 neuron pada hidden layer dan nilai bias dan bobot sebesar 3,1. Berikut merupakan hasil dari pengujian yang telah dilakukan yang menampilkan nilai MSE terbaik yang diperoleh pada rentang iterasi 10.000.

Tabel 6. MSE Terendah *Split Validation*

Jumlah Neuron	Nilai MSE	
	Data Latih	Data Uji
60:40	0,0061 (Iterasi 6620)	0,0040 (Iterasi 5925)
70:30	0,0076 (Iterasi 4943)	0,0065 (Iterasi 4565)
80:20	0,0083 (Iterasi 4211)	0,0079 (Iterasi 4021)
90:10	0,0094 (Iterasi 4029)	0,0063 (Iterasi 9249)

Berdasarkan Tabel 6, dapat diketahui pembagian dataset terbaik diperoleh pada rasio 60:40 dengan nilai MSE yang paling rendah pada data latih dan data uji di 0,0061 (Iterasi 6.620) pada data latih dan 0,0040 (Iterasi 5.925) pada data uji. *Split ratio* 60:40 tetap menjadi *data split* terbaik setelah urutan pengujiannya diacak.


4.6. Knowledge

Setelah data telah diolah, adapun *knowledge* yang diperoleh adalah:

4.6.1. Tingkat Akurasi Prediksi

Model backpropagation neural network terbaik dengan parameter laju pembelajaran sebesar 0,2, jumlah neuron pada hidden layer sebesar 2 neuron, nilai bias dan bobot sebesar 3,1, jumlah iterasi sebanyak 5925, dan pembagian dataset terbaik diperoleh pada rasio 60:40. Karena nilai MSE data uji

sebesar 0,0040 dengan tingkat akurasi 99,06%. Berikut merupakan gambar grafik tingkat akurasi hasil pengujian menggunakan parameter terbaik yang diperoleh.



Gambar 2. Grafik Akurasi Data Latih dan Data Uji

Berdasarkan gambar 4.5 dapat dilihat bahwa pada data latih, tingkat akurasi data yang benar diprediksi sebesar 97,92% atau 470 dari 480 data dan prediksi yang salah sebesar 2,08% atau 10 dari 480 data. Perusahaan yang diprediksi berpotensi mengalami kebangkrutan sebanyak 81 perusahaan dan 399 perusahaan yang tidak diprediksi mengalami kebangkrutan.


Pada data uji, tingkat akurasi data yang benar diprediksi sebesar 99,06% atau 317 dari 320 data dan prediksi yang salah sebesar 0,94% atau 3 dari 320 data. Perusahaan yang diprediksi berpotensi mengalami kebangkrutan sebanyak 53 perusahaan dan 267 perusahaan yang tidak diprediksi mengalami kebangkrutan.

Berdasarkan hasil prediksi, terdapat 134 perusahaan yang diprediksi berpotensi mengalami kebangkrutan. Sedangkan, sebanyak 666 perusahaan tidak diprediksi mengalami kebangkrutan. Berikut merupakan daftar perusahaan yang diprediksi berpotensi mengalami kebangkrutan, diantaranya ABBA, ACST, ADMG, AGRS, AHAP, AISA, AKKU, ANTM, APEX, ARCI, ARGO, ARTI, BATA, BELI, BIKI, BIPI, BKDP, BLTZ, BPTR, BTEK, BTEL, BUKK, BULL, BUVA, BWPT, CENT, CLAY, CMNT, CMPP, CNKO, CNTX, CSMI, DART, DAYA, DEAL, DEWA, DIGI, EAST, EPAC, ETWA, EXCL, FAST, FASW, FIRE, FITT, FOOD, FREN, GLOB, GMFI, GOTO, GTRA, HDTX, HELI, HERO, HKMU, IBFN, ICON, IIKP, IKAI, IMAS, IMJS, INAF, INAI, INDX, INKP, INOV, INPS, INTA, JAST, JAWA, JGLE, KARW, KBLV, KINO, KMTR, KOIN, KRAS, LINK, LRNA, MAPB, MARI, MBTO, MGNA, MIRA, MPOW, MPPA, MPRO, MSKY, MTPS, MYTX, NPGF, OCAP, OMRE, PACK, PDES, PGJO, PKPK, PLAN, PNSE, POLY, POSA, PRAS, PSAB, PSDN, PTDU, PZZA, RANC, RONY, SAFE, SAGE, SBAT, SIPD, SMRU, SQMI, SRAJ, SRIL, SWAT, TAMA, TAMU, TBIG, TDPM, TELE, TIRT, TOBA, TRIO, TRUK, UANG, UNSP, VIVA, VOKS, WICO, WMPP, WMUU, WSBP.

a. Model Prediksi

Dari pengujian yang telah dilakukan, didapatkan model *feedforward propagation* yang dapat digunakan untuk memprediksi potensi kebangkrutan.

Berikut ditampilkan arsitektur jaringan syaraf tiruan propagasi maju untuk memprediksi potensi kebangkrutan.



Gambar 3. Arsitektur JST untuk Memprediksi Potensi Kebangkrutan

Berdasarkan gambar 3, nilai bobot yang menghubungkan neuron input ROA, WCTA, ROTA dan CR dengan hidden layer masing-masing adalah -39.9003251, -42.0438567, -41.4049811, dan -0.00597372124. Nilai bobot yang menghubungkan hidden layer dengan output layer adalah 3.22933669. Nilai bias yang digunakan dalam hidden layer dan output layer adalah -2.96224343.

Untuk mengetahui apakah model yang dibuat sudah akurat atau tidak, akan dilakukan pengujian menggunakan 320 data. Berikut merupakan *source code feedforward propagation*:

```
import numpy as np

X = x
def sigmoid(x):
    return 1 / (1 + np.exp(-x))

learning_rate = 0.2
input_size = 4
hidden_size = 2
output_size = 1

W1 = np.array([
    [-39.9003251, -39.9003251],
    [-42.0438567, -42.0438567],
    [-41.4049811, -41.4049811],
    [-0.00597372124, -0.00597372124]
])
b1 = np.array([[-2.96224343, -2.96224343]])
W2 = np.array([
    [3.22933669],
    [3.22933669]
])
b2 = np.array([[ -2.96224343]])

for i in range(X.shape[0]):
    Z1 = np.dot(X[i], W1) + b1
    A1 = sigmoid(Z1)
    Z2 = np.dot(A1, W2) + b2
    A2 = sigmoid(Z2)

threshold = 0.5
```

```

binary_output = (A2 >=
threshold).astype(int)

print(f"Input {i + 1}:")
print("Input Data:")
print(X[i])
print("Hasil:")
print(A2)
print("Setelah Dibulatkan:")
print(binary_output)
if binary_output == 0:
    print("Perusahaan tidak
berpotensi mengalami Kebangkrutan")
else:
    print("Perusahaan berpotensi
mengalami Kebangkrutan")
print()

```

Berdasarkan dari hasil pengujian prediksi potensi kebangkrutan dari *source code feedforward propagation* yang diperoleh menghasilkan tingkat akurasi sebesar 99,06% atau 317 data yang diprediksi dengan benar dan 0.94% atau 3 data yang salah diprediksi.

5. KESIMPULAN DAN SARAN

Hasil prediksi potensi kebangkrutan perusahaan yang terdaftar pada BEI menggunakan algoritma *Backpropagation Neural Network* terdapat 134 perusahaan yang diprediksi berpotensi mengalami kebangkrutan dan 666 perusahaan yang diprediksi tidak mengalami kebangkrutan. Hasil implementasi algoritma *backpropagation neural network* pada proses klasifikasi dan prediksi data perusahaan yang terdaftar pada BEI dengan menggunakan 480 data latih dan 320 data uji memperoleh tingkat akurasi sebesar 99,06% dengan menggunakan parameter laju pembelajaran sebesar 0,2, jumlah *neuron* pada *hidden layer* sebesar 2 *neuron*, nilai bias dan bobot sebesar 3,1, jumlah iterasi sebanyak 5925. Hasil ini menunjukkan bahwa nilai prediksi kebangkrutan mendekati nilai target yang diinginkan. Hal tersebut dikarenakan tingkat rata-rata kesalahan jaringan yang dihasilkan sangat kecil sehingga nilai MSE yang dihasilkan berada di angka 0,004 yang menunjukan tingkat akurasi dari algoritma ini sangat tinggi.

Terdapat hal-hal yang dapat dipertimbangan dalam penelitian dimasa depan. Pertama, menambahkan jumlah data Perusahaan dengan menambah periode laporan keuangan menjadi 2 tahun atau lebih untuk mendapatkan sampel data yang lebih bervariasi sehingga model yang dihasilkan bisa memprediksi lebih baik. Kedua, dengan dihasilkannya model prediksi potensi kebangkrutan pada penelitian ini, penelitian kedepannya diharapkan bisa merancang aplikasi agar memudahkan pembaca yang ingin melakukan prediksi potensi kebangkrutan

DAFTAR PUSTAKA

- [1] Badan Pusat Statistik, "Ekonomi Indonesia 2020 Turun sebesar 2,07 Persen (c-to-c),"

Badan Pusat Statistik, 5 Februari 2021. [Online]. Available:

<https://www.bps.go.id/pressrelease/2021/02/05/1811/ekonomi-indonesia-2020-turun-sebesar-2-07->. [Accessed April 2023].

- [2] Indonesia Stock Exchange, "Notasi Khusus," Indonesia Stock Exchange, 2023. [Online]. Available: <https://www.idx.co.id/id/perusahaan-tercatat/notasi-khusus>. [Accessed April 2023].
- [3] Darsono and Ashari, Pedoman Praktis Memahami Laporan Keuangan, Jakarta: Andi, 2005.
- [4] R. A. Nurdini, Y. Priyadi and Norita, "Analisis Prediksi Kebangkrutan Perusahaan Menggunakan Artificial Neural Network Pada Sektor Pertambangan Batubara," *Jurnal Sistem Informasi Bisnis*, vol. 8, no. 1, pp. 107-114, 2019.
- [5] S. W. Harjono, N. W. Utami and I. G. A. Pramesti Dwi Putri, "Klasterisasi Tingkat Penjualan pada Startup Panak.id dengan Algoritma K-Means," *Jurnal Ilmiah Teknologi Informasi Asia*, pp. 55-66, 2023.
- [6] BINUS, "Mengenal Artificial Neural Network," BINUS, 2022. [Online]. Available: <https://sis.binus.ac.id/2022/02/14/mengenal-artificial-neural-network/>. [Accessed April 2023].
- [7] K. S. Pertiwi, "Analisis Keakuratan Metode Altman Z-Score, Springate, Grover,," uii, Yogyakarta, 2020.
- [8] D. Fitrianiingsih, "ENGARUH CURRENT RATIO, DEBT RATIO, NET PROFIT MARGIN DAN RETURN ON EQUITY TERHADAP FINANCIAL DISTRESS," *AKUNTANSI DEWANTARA*, vol. 5, no. 2, pp. 48-61, 2021.
- [9] KlikPajak, "Pengertian ROA (Return On Asset) beserta Rumus dan Contohnya," klikpajak, 27 November 2022. [Online]. Available: <https://klikpajak.id/blog/return-on-asset/>. [Accessed April 2023].
- [10] Rosmayanti, "PENGUNAAN RASIO KEUANGAN DALAM MEMREDIKSI PERTUMBUHAN LABA PADA," *Equilibrium*, vol. 7, no. 2, pp. 70 - 89, 2018.
- [11] W. KENTON, "Return on Total Assets (ROTA): Overview, Examples, Calculations," investopedia, 29 May 2021. [Online]. Available: https://www.investopedia.com/terms/r/return_on_total_assets.asp. [Accessed April 2023].