

PREDIKSI KEBANGKRUTAN MENGGUNAKAN JARINGAN SARAF BUATAN

BANKRUPTCY PREDICTION USING ARTIFICIAL NEURAL NETWORKS

Stradivarius Melvin Petra, stradivariusedmelvin@gmail.com¹⁾, I Gusti Ngurah Suryantara, gusti@bundamulia.ac.id²⁾, Felliks Feiters Tampinongkol, ftampinongkol@bundamulia.ac.id³⁾

¹⁾²⁾³⁾Program Studi Informatika, Universitas Bunda Mulia

Diterima 26 Maret 2024 / Disetujui 31 Juli 2024

ABSTRACT

The worst thing about financial failure is bankruptcy. The bankruptcy of a company can be analyzed from financial statements. the results of financial statement analysis is very useful for corporate leaders and investors to know the true condition of the company. Financial statement analysis can be done by calculating financial ratios. This study uses five variable financial ratios to predict corporate bankruptcy with repeated neural networks that apply Elman model. The sample data used in this study are 50 companies listed on the IDX 2007-2010 period. data is divided into two groups, 80% for training data and 20% for test data. Based on the function obtained from the training data, 10 companies will be tested. The best results from testing show that 9 out of 10 got the correct data.

Keywords: Artificial Recurrent Neural Network Elman, Bankruptcy Prediction, Financial Ratio

ABSTRAK

Hal terburuk dari kegagalan finansial adalah kebangkrutan. Kebangkrutan suatu perusahaan dapat dianalisis dari laporan keuangan. hasil analisis laporan keuangan sangat berguna bagi pimpinan perusahaan dan investor untuk mengetahui kondisi sebenarnya dari perusahaan. Analisis laporan keuangan dapat dilakukan dengan menghitung rasio keuangan. Penelitian ini menggunakan lima variabel rasio keuangan untuk memprediksi kebangkrutan perusahaan dengan jaringan syaraf tiruan yang berulang penerapan model Elman. Data sampel yang digunakan dalam penelitian ini adalah 50 perusahaan yang terdaftar di BEI periode 2007-2010. data dibagi menjadi dua kelompok, 80% untuk data pelatihan dan 20% untuk data uji. Berdasarkan fungsi yang didapatkan dari hasil data pelatihan, 10 perusahaan akan diuji. Hasil terbaik dari pengujian menunjukkan bahwa 9 dari 10 mendapat data yang benar.

Kata Kunci: Jaringan Saraf Tiruan Elman, Prediksi Kebangkrutan, Rasio Keuangan

PENDAHULUAN

Selain memperhatikan faktor yang dapat membuat perusahaan sukses, kegagalan bisnis dan kebangkrutan juga merupakan hal penting untuk di pahami, sebab bisnis selalu mempunyai kecenderungan untuk mengalami kesulitan bahkan kegagalan finansial. Bentuk paling buruk dari kegagalan finansial adalah kebangkrutan. Kebangkrutan atau kepailitan bagi perusahaan merupakan deklarasi akhir dari ketidakmampuan untuk menjalankan operasional perusahaan, serta banyaknya tanggungan hutang-hutang yang belum dapat dipenuhi kewajibannya. Hampir semua perusahaan harus memiliki beberapa hutang untuk memperluas operasi atau hanya untuk bertahan hidup.

Tingkat dimana suatu perusahaan memiliki hutang lebih dari asetnya atau tidak mampu membayar hutang merupakan dua faktor yang paling umum dalam kebangkrutan. Oleh karena itu

*Korespondensi Penulis:

E-mail: gusti@bundamulia.ac.id

kegagalan usaha dapat menciptakan biaya tinggi dan kerugian besar sehingga dibutuhkan sebuah prediksi. Jika kebangkrutan bisa diperkirakan atau diprediksikan dengan cukup akurat dari waktu ke depan, perusahaan dapat melindungi bisnis mereka dan bisa mengambil tindakan untuk meminimumkan resiko dan kerugian bisnis dan bahkan mencegah kebangkrutan itu sendiri.

Penelitian sebelumnya mengenai analisa prediksi kebangkrutan perusahaan dengan menggunakan laporan keuangan telah dilakukan dengan Menggunakan *Artificial Neural Network* (ANN), bahwa metode ANN dengan Algoritma *Backpropagation* mampu memprediksi kebangkrutan perusahaan akibat kesulitan keuangan dengan tingkat keakurasian mencapai lebih dari sama dengan 80%. [1][2]

Secara umum, algoritma jaringan ini membutuhkan waktu pembelajaran yang lambat, tetapi setelah pembelajaran dan pelatihan selesai, aplikasinya akan memberikan *output* yang sangat cepat. Untuk mendapatkan kinerja yang lebih optimal dari algoritma tersebut dapat diselesaikan dengan variasi *backpropagation* yang telah banyak dikembangkan untuk meningkatkan kecepatan proses *training* yang dikenal dengan optimasi teknik heuristik yaitu algoritma pelatihan yang berfungsi untuk lebih mempercepat proses *training* (pelatihan) dan merupakan pengembangan dari suatu analisa kinerja pada algoritma *steepest (gradient) descent standard*. [3]

Tidak seperti pada *backpropagation*, jaringan model Elman, mempunyai fungsi aktivasi yang dapat berupa sembarang fungsi, baik yang kontinu maupun diskontinu. Delay yang terjadi pada hubungan antara lapisan *input* dengan *hidden layer* pertama pada waktu sebelumnya dapat digunakan untuk saat ini dimana apabila kita mempunyai dua jaringan *recurrent* dengan bobot awal yang sama dan diberikan pada *input* yang sama, bisa jadi akan menghasilkan *output* jaringan yang berbeda. Dengan adanya koneksi pada *hidden layer* ini memungkinkan jaringan model Elman untuk dapat mendeteksi serta menghasilkan pola data *time series* yang bervariasi dan hal ini sangatlah cocok untuk mendeteksi model *load time series*. [4][5]

Penelitian Salman (2011) dalam Seminar Nasional Aplikasi Teknologi Informasi yang berjudul Implementasi Jaringan Saraf Tiruan Recurrent model Elman dengan metode pembelajaran *gradient descent adaptive learning rate* untuk pendugaan curah hujan, bahwa JST *recurrent* yang teroptimasi secara heuristik dapat diterapkan dalam pendugaan curah hujan dengan tingkat keakuratan yang cukup baik. [6]

Berdasarkan latar belakang diatas, penelitian ini bertujuan untuk mengangkat masalah tentang bagaimana Jaringan Saraf Tiruan *Recurrent* model Elman dapat memprediksi kebangkrutan perusahaan yang disebabkan oleh kesulitan keuangan.

TINJAUAN TEORI / KONSEP

Jaringan Saraf Tiruan

Jaringan Saraf Tiruan (*artificial neural networks*) atau disingkat JST adalah sistem komputasi dimana arsitektur dan operasi diilhami dari pengetahuan tentang sel saraf biologi di dalam otak. Jaringan saraf merupakan salah satu representasi buatan dari otak manusia yang mensimulasikan proses pembelajaran pada otak manusia tersebut. Istilah buatan disini digunakan karena jaringan saraf ini diimplementasikan dengan menggunakan program computer yang mampu menyelesaikan sejumlah proses perhitungan selama proses pembelajaran. [4][5]

JST merupakan sistem pemrosesan informasi yang memiliki karakteristik serupa dengan jaringan saraf biologis dengan ciri-ciri:

1. Pola hubungan antara elemen-elemen sederhana yakni *neuron*.
2. Metode penentuan bobot koneksi.
3. Fungsi aktivasinya.

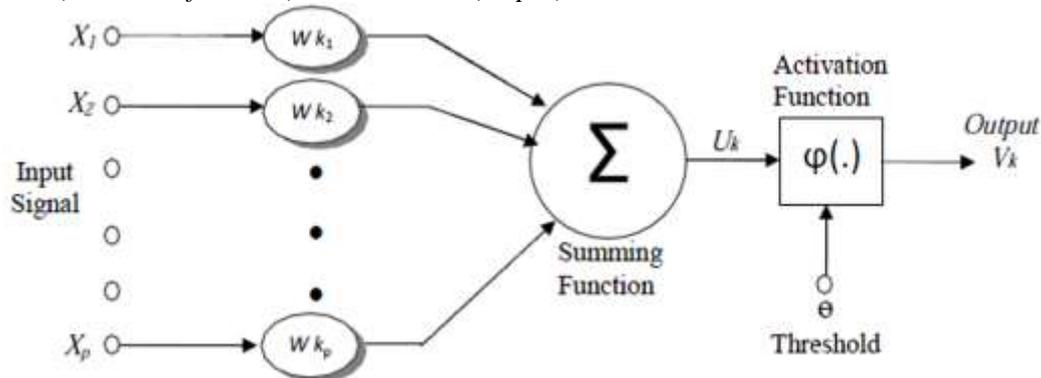
JST mempunyai sifat dan kemampuan: [3]

1. Akuisisi pengetahuan di bawah derau (*noise*) dan ketidakpastian (*uncertainty*).
2. Representasi pengetahuan yang fleksibel.

3. Pemrosesan pengetahuan yang efisien.
4. Toleransi kesalahan, dengan representasi pengetahuan terdistribusi dan pengkodean informasi yang redundan, kinerja sistem tidak menurun drastis berkaitan dengan responnya terhadap kesalahan.

Model Neuron

Satu sel saraf terdiri dari tiga bagian, yaitu fungsi penjumlahan (*summing function*), fungsi aktivasi (*activation function*), dan keluaran (*output*).



Gambar 1. Model Neuron (sumber: Haykin, 2001)

Informasi (*input*) akan dikirim ke *neuron* dengan bobot tertentu. *Input* ini akan diproses oleh suatu fungsi yang akan menjumlahkan nilai bobot yang ada. Pada Gambar 2.1, hasil penjumlahan kemudian akan dibandingkan dengan suatu nilai ambang (*threshold*) tertentu melalui fungsi aktivasi setiap *neuron*. Apabila *input* tersebut melewati suatu nilai ambang tertentu, maka *neuron* tersebut akan diaktifkan, jika tidak *neuron* tidak akan diaktifkan. Apabila *neuron* tersebut diaktifkan, maka *neuron* tersebut akan mengirimkan *output* melalui bobot-bobot *output*nya ke semua *neuron* yang berhubungan dengannya. [4][5]

Sehingga dapat disimpulkan bahwa *neuron* terdiri dari 3 elemen pembentuk yaitu :

1. Himpunan unit-unit yang dihubungkan dengan jalur koneksi. Jalur-jalur tersebut memiliki bobot yang berbeda-beda. Bobot yang bernilai positif akan memperkuat sinyal yang dibawa. Jumlah, struktur dan pola hubungan antar unit-unit tersebut akan menentukan arsitektur jaringan.
2. Suatu unit penjumlah yang akan menjumlahkan *input-input* sinyal yang sudah dikalikan dengan bobotnya.
3. Fungsi aktivasi yang akan menentukan apakah sinyal dari *input neuron* akan diteruskan ke *neuron* lain atau tidak.

Proses Pembelajaran

Umumnya, jika menggunakan Jaringan Saraf Tiruan, hubungan antara *input* dan *output* harus diketahui secara pasti dan jika hubungan tersebut telah diketahui maka dapat dibuat suatu model. Hal lain yang penting adalah proses belajar hubungan *input/output* dilakukan dengan pembelajaran.[3][4][5] Ada dua tipe pembelajaran yang dikenal yaitu :

1. Pembelajaran terawasi
Pada pembelajaran terawasi, metode ini digunakan jika *output* yang diharapkan telah diketahui sebelumnya. Biasanya pembelajaran dilakukan dengan menggunakan data yang telah ada.
2. Pembelajaran tak terawasi.
Pada metode pembelajaran yang tidak terawasi, tidak memerlukan target *output*. Pada metode ini tidak dapat ditentukan hasil seperti apa yang diharapkan selama proses pembelajaran. Selama proses pembelajaran, nilai bobot disusun dalam suatu range tertentu tergantung pada nilai *input* yang diberikan. Tujuan pembelajaran ini adalah

mengelompokkan unit-unit yang hampir sama dalam suatu area tertentu. Pembelajaran seperti ini biasanya sangat cocok untuk pengelompokkan (klasifikasi) pola.

Recurrent Neural Network

Recurrent Neural Network (RNN) adalah salah satu bagian dari model *artificial neural network*, yang mempunyai *feedback* yang berasal dari satu layer ke layer yang lain. Adapun yang termasuk dalam struktur *recurrent neural network* adalah sebagai berikut :[3]

- *Competitive networks*
- *Self-Organizing maps*
- *Elman networks*
- *Hopfield networks*
- *Jordan networks*
- *Adaptive-resonance theory models*

Recurrent Neural Network Elman

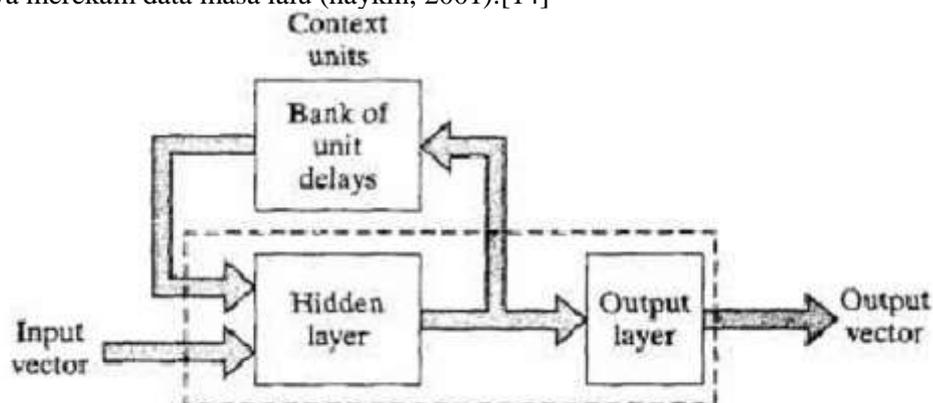
Jaringan rekurens sederhana (*simple recurrent network*) merupakan variasi dari Multi-Layer Perceptron sering disebut juga sebagai jaringan Elman karena ditemukan oleh Jeff elman. Perbedaan utama yang terdapat pada struktur ini adalah adanya beberapa *unit* yang berdekatan dengan layer *input* yang terhubung ke *hidden layer* seperti *input unit* yang lain. *Unit-unit* tersebut mengandung isi dari salah satu layer yang ada ketika pola sebelumnya dilatih.

Pada tiap langkahnya, masukan disebarakan dengan cara standar feedforward lalu suatu learning rule (biasanya *back-propagation*) digunakan. Hasil koneksi balik yang tetap (*fixed back connection*) di unit konteks merupakan salinan hasil dari unit hidden sebelumnya.

RNN Elman terdiri atas satu atau lebih *hidden layer*. Lapisan pertama memiliki bobot-bobot yang diperoleh dari lapisan *input*, setiap lapisan akan menerima bobot dari lapisan sebelumnya. Jaringan ini menggunakan fungsi aktivasi sigmoid bipolar untuk *hidden layer* dan fungsi linear (*purelin*) untuk lapisan keluaran.

Pada jaringan Elman ini, mempunyai fungsi aktivasi yang dapat berupa sembarang fungsi, baik yang kontinu maupun diskontinu. Delay yang terjadi pada hubungan antara lapisan *input* dengan *hidden layer* pertama pada waktu sebelumnya ($t-1$) dapat digunakan untuk saat ini (t) (Kusumadewi, 2004).[16][17]

Keunikan RNN *Elman* adalah adanya koneksi umpan balik yang membawa informasi gangguan (*noise*) pada saat masukan sebelumnya yang akan diakomodasikan bagi masukan berikutnya dapat dilihat pada Gambar 2. Karena sifat dari umpan balik ini, unit dapat terus mendaur ulang informasi melalui jaringan hingga langkah-langkah beberapa waktu, dan dengan demikian menemukan representasi waktu yang abstrak. Oleh karena itu jaringan saraf *recurrent* tidak hanya merekam data masa lalu (haykin, 2001).[14]



Gambar 2. Arsitektur *Simple Recurrent Network Elman* (sumber: Haykin, 2001)

Sebuah Simple Recurrent Network (Elman, 1990) memiliki umpan balik aktivasi yang mewujudkan memori jangka pendek. Lapisan diperbarui tidak hanya dengan *input* eksternal jaringan tetapi juga dengan aktivasi dari propagasi maju sebelumnya. Umpan balik ini dimodifikasi dengan satu set bobot untuk memungkinkan adaptasi otomatis melalui belajar misalnya *backpropagation* (Boden, 2001).[9][10]

Elman (1990) pada percobaannya menggunakan *backpropagation* terpotong. Dasar dari cara ini adalah menggunakan nilai keluaran dari *hidden layer*, $y_{hidden}(t-1)$ hanya sebagai masukan tambahan. Galat dalam lapisan status hanya digunakan untuk memodifikasi bobot untuk masukan tambahan ini. Untuk menemukan batasan-batasan kata dalam aliran berkelanjutan dari fonem. Input ke jaringan mewakili fonem saat ini. *Output* mewakili menebak jaringan terbaik seperti apa fonem berikutnya secara berurutan. peran unit konteks adalah untuk menyediakan jaringan dengan memori dinamis sehingga untuk mengkodekan informasi yang terkandung dalam urutan fonem, yang relevan dengan prediksi.[13][14][17]

METODOLOGI PENELITIAN

Metodologi penelitian merupakan petunjuk untuk memastikan bahwa semua langkah-langkah dan kegiatan penelitian lebih sistematis. Penjelasan dari metodologi penelitian dapat dilihat pada



Gambar 3. Tahapan Metodologi Penelitian

Berdasarkan Gambar 3 metodologi penelitian dalam pengerjaan tugas akhir meliputi enam tahapan, yaitu :

Identifikasi Masalah

Tahap identifikasi masalah merupakan tahapan awal dalam penelitian ini Pada tahap ini peneliti mempelajari tujuan, ruang lingkup dan metodologi penelitian. Serangkaian kegiatan yang dilakukan dalam tahap ini yaitu studi pustaka mengenai penelitian yang sudah ada, memilih topik

permasalahan yang dianggap menarik untuk penelitian dan mencari ide-ide baru atau pengembangan ide-ide yang sudah ada untuk penelitian baru. Studi pustaka ini dipelajari dari buku, situs internet, media elektronik dan media cetak.

Pengumpulan Data

Setelah dilakukan studi pustaka, tahap selanjutnya adalah menyiapkan data berupa rasio keuangan yang dihitung berdasarkan laporan keuangan perusahaan. Adapun pengambilan data laporan keuangan bertujuan untuk mendapatkan informasi tentang analisa memprediksi kebangkrutan perusahaan menggunakan jaringan saraf tiruan *recurrent*. Adapun sumber data, metode pengumpulan data dan jumlah data sebagai berikut : [1][2][6]

1. Sumber data perusahaan dan laporan keuangan diperoleh dengan meng-unduh di situs resmi Bursa Efek Indonesia (BEI)[1]
2. Metode pengumpulan data secara *time series*, oleh karena itu dalam penelitian ini dibutuhkan laporan keuangan perusahaan yang terdaftar di Bursa Efek Indonesia (BEI) periode 2007-2010. Mengingat waktu/periode perusahaan yang bankrut tidak sama, maka untuk perusahaan bankrut digunakan data keuangan satu atau dua tahun sebelum perusahaan mengalami kebangkrutan. 3. Jumlah data yang digunakan sebanyak 50 perusahaan, meliputi perusahaan yang masih aktif dan perusahaan yang tidak aktif.

Analisa Sistem

Setelah data terkumpul, tahap berikutnya adalah analisa kebutuhan pada sistem. Tahapan dari analisa kebutuhan sistem adalah sebagai berikut :

Analisa Rasio Perusahaan

Tahapan ini akan menganalisa laporan keuangan dengan menggunakan rasio keuangan model altman, dimana rasio-rasio tersebut akan menjadi variable masukan (*input*) pada jaringan.

Analisa Jaringan Model Elman

Pada tahap ini dilakukan analisa terhadap struktur jaringan saraf tiruan *recurrent*. Untuk mendapatkan unjuk kerja jaringan yang optimum dilakukan proses *trial & error* dengan parameter:

- Dimensi jaringan (jumlah *neuron* dan *hidden layer*)
- Laju pembelajaran (*learning rate*)

Setelah struktur jaringan terbentuk dari proses trial dan error, langkah selanjutnya adalah proses pelatihan (*training*) dan dilanjutkan dengan pengujian (*testing*).

Perancangan Sistem

Merancang kebutuhan data dengan cara pembuatan diagram konteks, DFD, ERD, Flowchart (*user interface*). Setelah melakukan analisa, maka kemudian dilanjutkan dengan perancangan sistem berdasarkan analisa permasalahan yang telah dilakukan sebelumnya.

Perancangan Basis Data

Setelah menganalisa sistem yang akan dibuat, maka tahap selanjutnya adalah perancangan basis data yang dilakukan untuk melengkapi komponen sistem.

Perancangan Struktur Menu

Rancangan struktur menu diperlukan untuk memberikan gambaran terhadap menu-menu atau fitur pada sistem yang akan dibangun.

Perancangan Antar Muka (Interface)

Untuk mempermudah komunikasi antara sistem dengan pengguna, maka perlu dirancang *interface*. Dalam perancangan *interface* hal terpenting yang ditekankan adalah bagaimana menciptakan tampilan yang baik dan mudah dimengerti oleh pengguna.

Implementasi

Rancangan perangkat lunak yang telah dibuat pada tahap perancangan kemudian dikodekan ke dalam bentuk kode program dengan menggunakan bahasa pemrograman PHP dan database MySQL agar dapat dijalankan pada komputer.

Pengujian & Evaluasi

Pada tahap ini, dilakukan pengujian terhadap sistem. Pengujian system dilakukan dengan cara menggunakan Black Box. Pengujian ini berfokus pada perangkat lunak untuk mendapatkan serangkaian kondisi input yang seluruhnya menggunakan persyaratan fungsional dalam suatu program. Untuk mendapatkan topologi terbaik dilakukan uji coba menggunakan RMSE.

ANALISIS HASIL

Pada tugas akhir ini akan dirancang sebuah perangkat lunak untuk prediksi kebangkrutan perusahaan berdasarkan laporan keuangan perusahaan yang pernah terdaftar (*listed*) di Bursa Efek Indonesia (BEI) dengan parameter-parameter yang telah ditentukan dengan metode Jaringan Saraf Tiruan (JST). Dengan memadukan jaringan model Elman dan algoritma backpropagation optimasi pembelajaran heuristik dapat menghasilkan model JST yang paling optimal. Bab ini akan membahas Analisa dan perancangan perangkat lunak yang akan dibuat.

Analisa Sistem

Sistem yang akan dibangun adalah sebuah sistem yang memprediksi kebangkrutan perusahaan dengan jaringan *recurrent* model elman. Sistem akan menerima *input* (data masukan) dari laporan keuangan perusahaan kemudian akan diproses dengan menerapkan model elman dan menghasilkan *output* (data keluaran) berupa prediksi bangkrut atau tidaknya perusahaan. Membangun Sistem Prediksi kebangkrutan perusahaan perlu dilakukan analisa dan perancangan sehingga sistem yang dibangun sesuai dengan tujuan yang ingin dicapai. Analisa yang dilakukan adalah analisa subsistem data berupa analisa rasio keuangan dan analisa jaringan model elman, proses prediksi. Setelah analisa dilakukan perancangan sistem.

Analisa Rasio Keuangan Perusahaan

Pada tahap ini dilakukan analisa terhadap data-data yang digunakan dalam membangun database agar sistem dapat berjalan sesuai harapan. Pada prediksi kebangkrutan perusahaan data-data yang dibutuhkan untuk pembuatan system diperoleh dari data laporan keuangan perusahaan.

Analisa Data

Sebelum data digunakan dalam penelitian ini, ada beberapa langkah penyiapan dan pemurnian data yang dilakukan, yaitu :

1. Seleksi data

Tahap pemilihan data dari sekumpulan data yang ada. Proses ini memilih data yang akan digunakan berdasarkan tahun, rasio keuangan yang digunakan dan kategori perusahaan yang bangkrut dan tidak bangkrut, kemudian disimpan dalam satu berkas.

Data yang digunakan dalam penelitian ini adalah laporan keuangan perusahaan yang pernah terdaftar (*listed*) di Bursa Efek Indonesia (BEI). Pemilihan BEI karena laporan keuangan perusahaan tersebut bersifat public dan sesuai dengan klasifikasi. Adapun beberapa tipe perusahaan yang memenuhi klasifikasi dalam penelitian ini yaitu,

- Perusahaan yang diajukan pailit oleh perusahaan lain dikarenakan tidak membayar utang dalam periode yang telah ditentukan.
- Perusahaan yang dinyatakan bangkrut oleh Pengadilan Niaga.
- Perusahaan mengalami *suspense* (pemberhentian sementara) oleh BEI dikarenakan perusahaan tidak sehat dalam keuangan.

- d. Perusahaan yang memiliki laporan keuangan sehat dalam periode tertentu dan masih tercatat di BEI.

Laporan keuangan perusahaan diambil dari direktori perusahaan *listed* dan *delisted* yang ada di situs resmi BEI. Data yang diambil berupa laporan keuangan mulai tahun 2007-2010. Sedangkan untuk perusahaan yang mengalami kebangkrutan, laporan keuangan diambil satu tahun sebelum terjadinya kebangkrutan, Hal ini sesuai dengan penelitian yang dilakukan oleh Altman (1968).

2. Data integration

Tahap ini dilakukan proses penggabungan data. Data dari setiap laporan dirubah terlebih dahulu menjadi rasio altman Contoh perhitungan rasio altman laporan keuangan salah satu perusahaan yaitu PT. Akbar Indo Makmur Stimec, Tbk dengan kode perusahaan AIMS tahun 2007:

$$\begin{aligned} x1 &= \text{Net working capital} / \text{Total asset} \\ &= 18,418,287,598 / 38,499,096,921 \\ &= 0.478 \\ x2 &= \text{Retained earning} / \text{Total asset} \\ &= 3,575,479,400 / 38,499,096,921 \\ &= 0.093 \\ x3 &= \text{EBIT} / \text{Total asset} \\ &= 874,839,356 / 38,499,096,921 \\ &= 0.023 \\ x4 &= \text{Market value of equity} / \text{Book value of debt} \\ &= 18,791,045,085 / 19,708,051,836 \\ &= 0.953 \\ x5 &= \text{Sales} / \text{Total asset} \\ &= 92,335,741,795 / 38,499,096,921 \\ &= 2.398 \end{aligned}$$

Setelah itu, data dari beberapa perusahaan digabungkan menjadi sebuah tabel perhitungan rasio keuangan perusahaan. Sebagaimana yang dapat lihat pada tabel berikut ini (selengkapnya dilampiran A):

Tabel 1: Rasio Keuangan

No.	KODE	NAMA PERUSAHAAN	Tahun	X1	X2	X3	X4	X5
1	AIMS	Akbar Indo Makmur Stimec	2007	0.478	0.093	0.023	0.953	2.398
			2008	0.247	0.060	0.023	0.329	2.148
			2009	0.115	0.030	0.006	0.128	1.224
			2010	0.147	0.041	0.004	0.170	1.582
2	SING	Singer Indonesia	2007	0.585	0.303	0.210	15.188	0.030
			2008	0.707	0.672	0.126	74.447	0.000
3	DKFT	Duta Kirana Finance Central Omega Resources	2007	0.587	2.380	0.334	0.402	0.157
			2008	0.279	2.544	0.404	0.612	0.019
			2009	-0.003	3.459	0.313	0.339	0.000
			2010	0.159	2.221	0.159	0.017	0.000
4	HDTX	Panasia Indosyntec	2007	0.037	0.708	0.003	1.135	0.722
			2008	-0.049	0.210	0.091	0.774	0.961
			2009	-0.112	0.241	0.001	1.009	0.860
			2010	-0.046	0.258	0.005	1.178	0.653
5	IKBI	Sumi Indo Kabel	2007	0.501	0.225	0.189	2.948	2.699
			2008	0.585	0.314	0.223	3.923	2.585
			2009	0.639	0.328	0.072	7.046	1.534
			2010	0.622	0.308	0.013	4.543	2.041

6	LION	Lion Metal Works	2007	0.693	0.536	0.170	3.672	0.831
			2008	0.715	0.582	0.225	3.874	0.907
			2009	0.768	0.641	0.166	5.229	0.728
			2010	0.798	0.678	0.165	5.911	0.684
7	ESTI	Ever Shine Tex	2007	0.168	0.051	0.039	1.005	0.939
			2008	0.145	0.010	0.056	0.886	1.073
			2009	0.152	0.025	0.029	0.980	1.040
			2010	0.091	0.021	0.006	0.783	1.055
8	DLTA	Delta Djakarta	2007	0.555	0.715	0.112	3.485	1.412
			2008	0.574	0.694	0.169	2.982	1.686
			2009	0.628	0.730	0.234	3.670	1.663
			2010	0.673	0.766	0.272	5.013	1.701
9	APOL	Arpeni Pratama Ocean Line	2007	0.134	0.112	0.051	0.438	0.009
			2008	0.080	0.073	0.008	0.284	0.008
10	TEJA	Texmaco Jaya	2007	-2.358	4.138	0.050	0.788	0.027
			2008	-2.626	4.680	0.002	0.809	0.167

3. Normalisasi Data

Proses pelatihan jaringan saraf tiruan akan lebih efisien dan efektif apabila data- data yang diinputkan berada pada *range* tertentu. Melatih data mentah secara langsung pada JST dapat membuat *node* mengalami saturasi dan kegagalan melakukan pelatihan (*training*). oleh karena itu data input harus melalui proses normalisasi terlebih dahulu sehingga berada pada range yang sama dengan fungsi aktivasi yaitu 0 dan 1.

Normalisasi data dengan menggunakan rumus sebagai berikut:

$$f(x) = \frac{x_i - x_{min}}{x_{max} - x_{min}}$$

Dengan:

X_i = data ke- i

X_{min} = data dengan nilai minimum

X_{max} = data dengan nilai maximum

Langkah pertama untuk melakukan proses normalisasi adalah menentukan rasio keuangan perusahaan yang akan di normalisasikan, misal rasio keuangan X_1 pada Tabel 2 diatas, kemudian tentukan nilai yang paling maksimum dan nilai yang paling minimum dari data tersebut. Untuk lebih jelasnya dapat dilihat seperti contoh berikut:

nilai maksimum untuk $X_1 = 0.798$

nilai minimum untuk $X_1 = -2.626$

dengan persamaan normalisasi diatas, maka:

$$\text{untuk AIMS tahun 2007 : } f(1) = \frac{0.478 - (-2.626)}{0.798 - (-2.626)} = 0.907$$

$$\text{untuk AIMS tahun 2008 : } f(2) = \frac{0.247 - (-2.626)}{0.798 - (-2.626)} = 0.839$$

sampai data yang ke-10 dapat dilihat dibawah ini:

Tabel 2: Normalisasi Data Untuk Rasio X_1

No.	KODE	Tahun	X_1
1	AIMS	2007	0.907
		2008	0.839
		2009	0.801
		2010	0.810
2	IKBI	2007	0.913
		2008	0.938
		2009	0.954
		2010	0.949

3	SING	2007	0.938
		2008	0.973
4	DKFT	2007	0.938
		2008	0.848
		2009	0.766
		2010	0.814
5	HDTX	2007	0.778
		2008	0.752
		2009	0.734
6	LION	2010	0.754
		2007	0.969
		2008	0.976
		2009	0.991
7	ESTI	2010	1.000
		2007	0.816
		2008	0.809
		2009	0.811
8	DLTA	2010	0.794
		2007	0.929
		2008	0.934
		2009	0.950
9	APOL	2010	0.963
		2007	0.806
10	TEJA	2008	0.790
		2007	0.078
		2008	0.000

4. Pembagian Data

Setelah data rasio keuangan perusahaan di normalisasikan tahap berikutnya adalah penyiapan data (*dataset*) dilakukan berdasarkan kebutuhan *input* data yang diterima oleh algoritma. Jumlah data yang digunakan dalam tugas akhir ini adalah 141 record dari 50 perusahaan. Jumlah data tersebut terdiri dari 20 perusahaan tidak bangkrut dan 30 perusahaan bangkrut.

Dataset tersebut dibagi ke dalam dua bagian untuk proses pengujian yaitu Sesuai dengan penelitian yang telah dilakukan oleh Shin (2005) mengenai *Bankruptcy Prediction Model*, yaitu membagi *dataset* secara acak menjadi 80% untuk *training set* dan 20% untuk *validation set*.

Analisa Jaringan Model Elman

Selain variabel *input*, didalam pembuatan sistem harus ditentukan arsitektur dari jaringan elman serta dibutuhkan parameter jaringan untuk memulai pelatihan.

Arsitektur Jaringan

Arsitektur yang digunakan dalam sistem ini adalah arsitektur jaringan syaraf tiruan feedforward yang terdiri dari tiga layer, yaitu :

1. Satu *input layer*

Pada *input layer* ini terdiri dari 5 neuron yang merupakan inputan masukkan pada proses awal pembelajaran

2. Satu *hidden layer*

Berbeda dengan *input layer*, pada *hidden layer* jumlah neuron ditentukan secara trial dan error untuk mendapatkan hasil yang terbaik, pada percobaan kali ini dibatasi maksimal terdiri dari 10 neuron. Jumlah neuron pada *hidden layer* dari waktu sebelumnya juga menentukan jumlah neuron masukkan tambahan pada *input layer*.

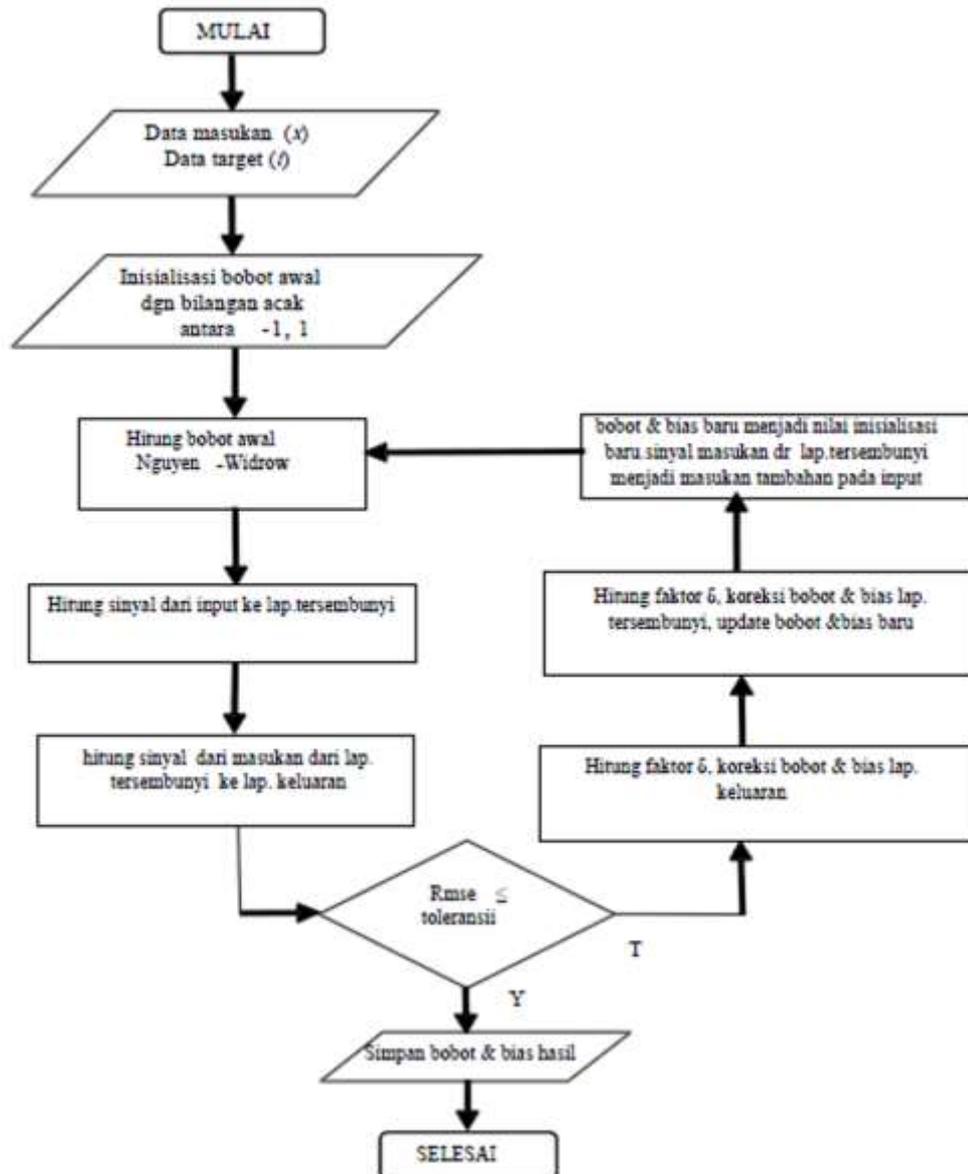
3. Satu *output layer*

Pada *output layer* terdiri dari satu neuron.

Parameter Pembelajaran

Parameter jaringan meliputi penentuan bobot awal (menggunakan algoritma nguyen-widrow), maksimum epoch dan galat sebagai kriteria pemberhentian JST serta learning rate (α) yang mana dalam pelatihan akan dicoba dilakukan perubahan parameter untuk melihat parameter manakah yang dapat menghasilkan sistem jaringan yang terbaik.

Setelah ditentukan neuron setiap layer dan parameter pembelajaran langkah selanjutnya adalah proses pelatihan jaringan (*training*). Berikut *flowchart* proses pelatihan jaringan:

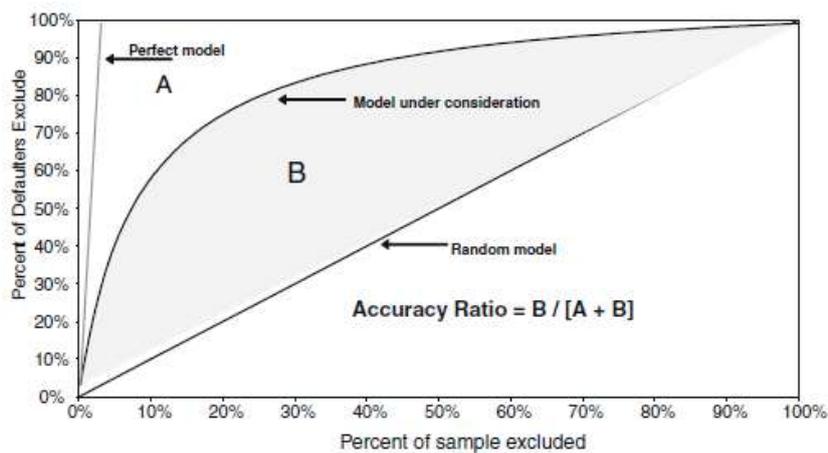
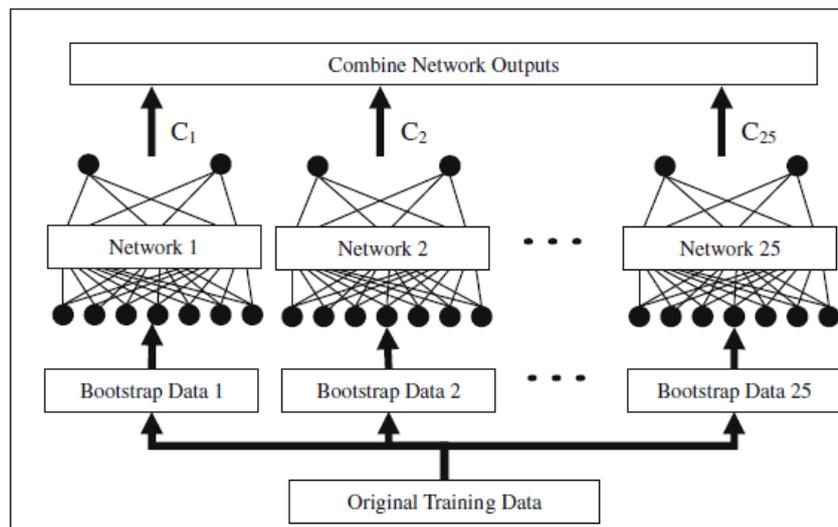
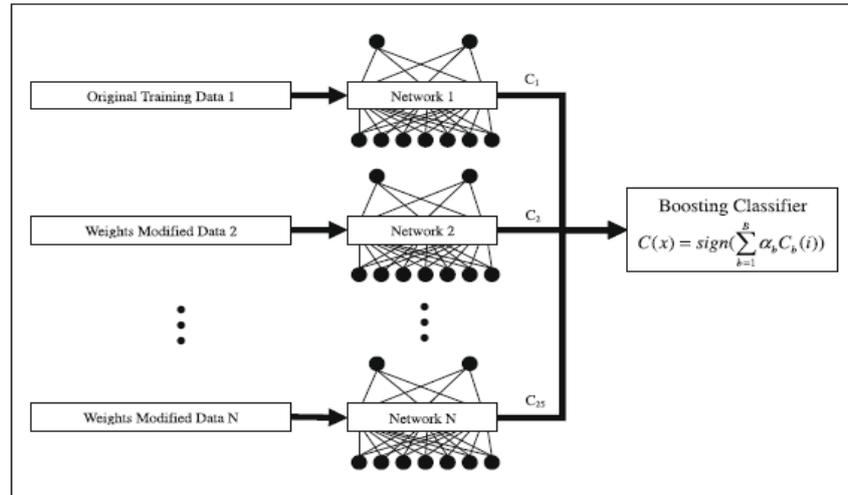


Gambar 4. Flowchart proses pelatihan jaringan

DISKUSI / PEMBAHASAN

Kami mengulangi 10 kali lipat validasi silang selama lima kali dengan benih acak yang berbeda seperti yang dilakukan oleh Optiz dan Maclin (1999) untuk memastikan bahwa perbandingan antara tiga pengklasifikasi berbeda tidak terjadi secara kebetulan. Untuk setiap validasi silang 10 kali lipat, seluruh kumpulan data (1458 firma) dipartisi pertama menjadi 10 set

yang berukuran sama, dan kemudian setiap set pada gilirannya digunakan sebagai set uji sementara pengelompokan tersebut melatih pada sembilan set yang lain. Artinya, lipatan yang divalidasi silang diuji secara independen dari masing-masing algoritma.



Gambar 5. Ilustrasi hasil pengujian

Dengan cara ini kami memperoleh hasil untuk tiga pengklasifikasi pada masing-masing 50 percobaan. Tabel 3 menggambarkan akurasi prediksi rata-rata setiap penggolong. Dalam semua 10 topologi yang berbeda, pengklasifikasi dikantongi dan digalakkan secara konsisten menghasilkan hasil yang lebih akurat daripada NN. Uji-t digunakan untuk menguji apakah kinerja prediksi rata-rata dari tiga pengklasifikasi untuk 50 lipatan secara signifikan berbeda. Hasil t-test menunjukkan bahwa classifier yang dikantongi mengungguli classifier yang ditingkatkan dan classifier NN pada tingkat signifikansi statistik 1% dan classifier yang dikuatkan pada gilirannya mengungguli NN classifier pada tingkat signifikansi statistik 1%. Ini menyiratkan bahwa dua metode ensemble dapat menjadi alat yang efektif untuk meningkatkan kinerja NN dalam domain prediksi kebangkrutan. NN Bagged menunjukkan hasil yang lebih baik dan kemampuan lean yang lebih stabil daripada pengklasifikasi lainnya, sementara NN yang dikuatkan menghasilkan peningkatan kinerja yang relatif kecil dibandingkan dengan classifier yang dikantongi. Salah satu alasan utama adalah bahwa NN terdongkrak bisa kehilangan kesempatan untuk meningkatkan kinerja karena kendala dalam generasi penggolong baru yang tergantung pada kinerja penggolong sebelumnya, sementara Bagging tidak memiliki kendala dalam generasi penggolong baru karena tidak bergantung pada kinerja penggolong sebelumnya ketika resampling dari set pelatihan. Bahkan, kami mengamati bahwa sebagian besar NN yang ditingkatkan untuk 50 kali lipat memiliki kurang dari 10 penggolong basis. Alasan lain yang mungkin adalah bahwa NN digunakan sebagai classifier dasar bisa menjadi hambatan untuk menghasilkan classifier baru karena pra-dewasa menyatu kesalahan pengujian yang ditetapkan pada sekitar 50% sebelum belajar meningkatkan NN.

Tabel 3: Comparison of predictive accuracy

Topology	NN			Boosted NN			Bagged NN		
	Training	Testing	Dif.	Training	Testing	Dif.	Training	Testing	Dif.
7-5-2	74.71	71.06	3.66	75.58	75.04	0.54	76.46	75.99	0.47
7-6-2	74.81	70.78	4.03	75.29	75.03	0.26	76.51	75.92	0.58
7-7-2	74.73	71.12	3.60	75.51	75.24	0.28	76.56	75.92	0.64
7-8-2	74.84	71.12	3.71	75.95	74.90	1.05	76.56	76.06	0.50
7-9-2	74.81	70.92	3.89	75.92	75.24	0.67	76.34	75.86	0.48
7-10-2	74.82	70.92	3.90	75.54	74.62	0.91	76.43	75.78	0.65
7-11-2	74.84	70.85	3.99	75.76	75.58	0.17	76.49	75.99	0.50
7-12-2	74.80	71.19	3.60	75.66	74.96	0.70	76.51	76.20	0.31
7-13-2	74.84	71.12	3.72	75.87	75.18	0.70	76.53	75.92	0.61
7-14-2	74.84	71.12	3.30	75.96	75.18	0.78	76.37	76.06	0.30
Average	74.80	71.02	3.78	75.70	75.10	0.60	76.47	75.97	0.50

Tabel 4: Comparison of prediction error rate

Topology	NN			Boosted NN			Bagged NN		
	Overall (%)	Type I (%)	Type II (%)	Overall (%)	Type I (%)	Type II (%)	Overall (%)	Type I (%)	Type II (%)
7-5-2	28.94	23.05	34.84	24.96	16.61	33.32	24.01	16.88	31.14
7-6-2	29.22	22.91	35.53	24.97	17.97	31.97	24.08	17.30	30.86
7-7-2	28.88	23.05	34.71	24.76	17.15	32.37	24.08	17.16	31.00
7-8-2	28.88	23.18	34.57	25.10	17.70	32.50	23.94	17.16	30.72
7-9-2	29.08	23.32	34.84	24.76	16.46	33.05	24.14	17.29	31.00
7-10-2	29.08	23.46	34.71	25.38	20.16	30.58	24.22	17.57	30.86
7-11-2	29.15	23.59	34.71	24.42	19.34	29.49	24.01	17.43	30.59
7-12-2	28.81	23.46	34.16	25.04	17.97	32.09	23.80	17.16	30.45
7-13-2	28.88	23.59	34.16	24.82	15.92	33.73	24.08	17.16	31.00
7-14-2	28.46	23.59	33.33	24.83	19.61	30.03	23.94	17.15	30.73
Average	28.94	23.32	34.55	24.90	17.89	31.91	24.03	17.23	30.83

Tabel 3 juga menunjukkan bahwa ensemble dengan NN berguna untuk mengatasi masalah overfitting NN. NN menunjukkan hasil yang lebih buruk pada set pengujian daripada set pelatihan. Perbedaan rata-rata akurasi adalah 3,78%, sedangkan dari dua metode ensemble

dikurangi menjadi 0,60% dan 0,50%, masing-masing. Ini berarti bahwa dua metode yang diusulkan mampu mengurangi kesenjangan akurasi (atau kesalahan generalisasi) karena kekokohan overfitting.

Tabel 4 menjelaskan kesalahan generasi, kesalahan Tipe I, dan kesalahan Tipe II dari tiga pengklasifikasi dalam set pengujian. Ada pengurangan 8,60% dengan belajar meningkatkan NN dibandingkan dengan kesalahan tes NN, yaitu 28,94% dan pengurangan 16,97% dengan pembelajaran NN dikantongi. Kesalahan Tipe I adalah tingkat kesalahan klasifikasi ketika misclassify perusahaan bangkrut sebagai perusahaan non-bangkrut sedangkan Tipe II kesalahan adalah tingkat misclassification ketika misclassify perusahaan non-bangkrut sebagai perusahaan bangkrut. Kesalahan Tipe I dianggap sebagai kesalahan paling penting karena dampaknya yang signifikan. NN Boosted dan NN dikantongi menurunkan error Tipe I masing-masing sebesar 76,72% dan 73,89%.

Dalam pembelajaran ensemble, adalah berguna untuk memvisualisasikan perilaku penggolongan ensemble dengan memplot grafik kumulatif dari marginnya. Margin contoh, dalam pembelajaran ensemble, didefinisikan sebagai perbedaan antara jumlah penggolong basis yang benar dan maksimum di antara jumlah penggolong basis yang melekat pada masing-masing label kelas, dan dengan demikian, mencerminkan kepastian klasifikasi. Oleh karena itu, jika ada label dua kelas {0, 1} dan kami memperbaiki '1' sebagai label yang benar tanpa kehilangan keumuman, maka $m(x)$, margin m dari sebuah instance x didefinisikan sebagai rumus (1).

$$m(x) = \frac{(\# \text{ of correct base classifiers}) - (\# \text{ of incorrect base classifiers})}{\# \text{ of base classifiers}} \quad (1)$$

Ketika semua pengklasifikasi dasar mengklasifikasikan dengan benar instance yang diberikan, margin instance adalah 1. Jika jumlah label kelas lebih dari dua, untuk menghitung margin, kami mengukur perbedaan antara jumlah penggolong basis yang benar dan jumlah maksimum pengklasifikasi antara label kelas yang salah. Dengan demikian definisi margin digeneralisasikan sebagai rumus (2).

$$m(x) = \frac{(\# \text{ of correct base classifiers}) - \max(\# \text{ of base classifiers that predict class label } i)}{\# \text{ of base classifiers}} \quad (2)$$

Jadi, jika semua pengklasifikasi basis salah memprediksi ke satu label kelas tertentu, marginnya akan menjadi 1. Untuk membantu pemahaman manusia secara visual pada perilaku penggolongan ensemble, Kuncheva (2004) memperkenalkan grafik distribusi kumulatif dari margin. Dalam grafik, sumbu x mewakili margin, m , dan sumbu y mewakili persentase contoh yang marginnya kurang dari atau sama dengan m . Jika semua contoh diklasifikasikan dengan benar, maka grafik hanya berupa garis vertikal pada $m = 1$.

Tabel 5: Variance information factors

Variable	VIF
Ordinary income to total assets	1.66
EBITDA to Interest expenses	2.31
Total debt to total assets	1.97
Retained earning to total assets	2.74
Cash ratio	1.64
Inventory to sales	1.69
Total assets	1.61

Gambar 4 menunjukkan grafik kumulatif margin dari pengklasifikasi yang dikantongi dan digalakkan untuk 10 topologi NN yang berbeda. Sangat menarik untuk melihat bahwa ensamble Boosted membentuk kurva yang mirip dengan 'S' (ditampilkan dalam garis tipis pada Gambar. 4), tetapi ansamble Bagged membentuk kurva yang mirip dengan 'N' (ditampilkan dalam garis tebal pada Gambar. 4). Seperti disebutkan sebelumnya, itu karena distribusi sampel dari classifier dalam ensamble Boosted tergantung pada hasil classifier pendahulunya. Oleh karena itu, dalam hal distribusi sampel dan menghasilkan bobot jaringan neural, pengklasifikasi dasar dalam ansamble Boosted memiliki variasi yang lebih besar di antara mereka sendiri daripada penggolong basis dalam ansamble Bag.

SIMPULAN

Kesimpulan

Setelah melalui tahap pengujian pada aplikasi prediksi kebangkrutan dengan implementasi jaringan saraf tiruan *recurrent* Model Elman maka dapat diambil beberapa kesimpulan sebagai berikut :

1. Aplikasi prediksi kebangkrutan ini telah berhasil dirancang dan diimplementasikan dalam bentuk aplikasi berbasis web untuk memprediksi perusahaan dimana *output* yang dikeluarkan berupa keterangan “bangkrut” dan “tidak bangkrut”.
2. Penerapan jaringan saraf tiruan *recurrent* model elman ini telah berhasil untuk memberikan kemungkinan atas kondisi perusahaan berdasarkan laporan keuangan masing-masing perusahaan, ini dapat dilihat dari hasil pengujian dengan menggunakan 10 unit *hidden layer* yang mana 9 dari 10 perusahaan yang diuji mendekati kondisi perusahaan yang sebenarnya.

Saran

Beberapa hal yang dapat diungkap sebagai saran untuk pengembangan Aplikasi ini adalah sebagai berikut :

1. Aplikasi masih belum bisa menganalisa lebih dalam untuk memberikan solusi terhadap kondisi perusahaan yang dinyatakan bangkrut sehingga kedepannya bisa dikembangkan dengan algoritma lain untuk pengelompokkan kondisi perusahaan lebih mendetail.
2. Lapisan tersembunyi (*hidden layer*) bisa dikembangkan lagi lebih dari satu untuk dapat lebih mengenali semua pola pada pelatihan agar dapat memprediksi lebih akurat.

DAFTAR PUSTAKA

- [1] Adnan, M.A. , Kurniasih, E. 2000. *Analisis Tingkat Kesehatan Perusahaan untuk Memprediksi Potensi Kebangkrutan dengan Pendekatan Metode Altman (Kasus pada Sepuluh Perusahaan di Indonesia)*. Jurnal Akuntansi dan Auditing Indonesia, Volume 4 No.2 Desember : hal 131-151.
- [2] Adnan, M.A. , Taufiq M. 2001. *Analisis Ketepatan Prediksi Metode Altman Terhadap Terjadinya Likuidasi Pada Lembaga Perbankan*.
- [3] D. C. Sulaiman and T. M. S. Mulyana, “Web-Based Writing Learning Application of Basic Hanacaraka Using Convolutional Neural Network Method,” *Ultimatics : Jurnal Teknik Informatika*, pp. 28–34, Jun. 2023, doi: 10.31937/ti.v15i1.2993.
- [4] M. Freddy and T. M. S. Mulyana, “Determining Computer Opponent’s Actions in Strategy Game Using K-Nearest Neighbour Algorithm,” *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 8, no. 3, Dec. 2022, doi: 10.28932/jutisi.v8i3.5137.

-
- [5] T.M.S. Mulyana, "SEGMENTASI CITRA MENGGUNAKAN HEBB-RULE DENGAN INPUT VARIASI RGB," *Jurnal Teknologi Informasi*, vol. 11, no. 1, Juni 2015, pp. 34–443, 2015.
- [6] *Jurnal Ekonomi & Auditing* Volume 5 No.2 Desember. Penerbit :Fakultas ekonomi Universtas Islam Indonesia. Yogyakarta.
- [7] Boden, Mikael. 2001. *A guide to recurrent neural networks and backpropagation*. [Online] Available http://www.itee.uq.edu.au/~mikael/papers/rn_dallas.pdf. Diakses: Agustus 2012.
- [8] Cynthia, G.Y.P. 2009. Prediksi Kebangkrutan Perusahaan Menggunakan *Artificial Neural Network*. Institut Teknologi Sepuluh Nopember Surabaya. <http://digilib.its.ac.id/prediksi-kebangkrutan-perusahaanmenggunakanartificial-neural-network-9167.html>. Diakses : Agustus 2012
- [9] Elman, J. L. 1990. *Finding Structure in Time. Cognitive Science*, 14:179-211
- [10] Fausset, Laurence. 1994. *Fundamental of Neural Network : Architecture, Algorithm, and Application*. New Jersey : Prentice-Hall
- [11] Foster, G. 1986. *Financial Statement Analysis*. 2nd Ed. Prentice Hall
- [12] Hadi, S., Anggraeni, A. 2008. *Pemilihan Prediktor Delisting Terbaik (Perbandingan Antara The Zmijewski model, The Altman Model, Dan The Springate Model)*. Universitas Islam Indonesia. [Online] Available
- [13] Harahap, S.S. 2006. *Analisis Kritis Atas Laporan Keuangan*. Jakarta : PT. RajaGrafindo Persada
- [14] Haykin, Simon. 2001. *Neural Network : A Comprehensive foundation*. Second Edition Prentice Hall, Inc.
- [15] Ike N.D, Yesy. 2011. *Identifikasi Kondisi Financial Distress Perusahaan Pertambangan Di Jakarta Islamic Index Dengan Aplikasi Model Z-Score Dan X-Score*. Universitas Islam Negeri Maulana Malik Ibrahim. [Online] Available http://lib.uin-malang.ac.id/?mod=th_detail&id=07510031 diakses 2 desember 2012
- [16] Kusumadewi, Sri. 2003. *Artificial Intelligence (Teknik dan Aplikasinya)*. Yogyakarta : Andi.
- [17] Kristanto, Andri. 2004. *Jaringan Saraf Tiruan (Konsep Dasar, Algoritma dan Aplikasi)*. Yogyakarta : Gava Media.