

BACKPROPAGATION NEURAL NETWORK UNTUK OPTIMASI AKURASI PADA PREDIKSI FINANCIAL DISTRESS PERUSAHAAN

Riska Yanu Fa'rifah dan Zulfiqar Busrah

Dosen Jurusan Teknik Informatika

Universitas Cokroaminoto Palopo

Email : riska.yanu@gmail.com, zulfiqarbusrahmath@gmail.com

ABSTRAK

Backpropagation neural network (BNN) merupakan salah satu metode *machine learning* yang sesuai untuk analisis data kualitatif (data biner). BNN ini digunakan untuk mendapatkan akurasi yang tinggi dari hasil analisis. Akurasi yang tinggi dapat diperoleh dengan menggunakan algoritma resilient BNN. Oleh karena itu penelitian ini akan menerapkan metode resilient BNN untuk mengoptimalkan akurasi berdasarkan hasil analisis prediksi financial distress dengan logistic regression (LR). Hasil analisis menunjukkan bahwa akurasi yang dihasilkan dengan resilient BNN meningkat 23.81% dari analisis sebelumnya, yaitu menggunakan LR dengan akurasi sebesar 66.67%. Akurasi optimum pada resilient BNN ini terjadi pada penggunaan 7 *hidden layer*.

Kata kunci : *akurasi, backpropagation neural network, financial distress, logistic regression, resilient BNN*

1. PENDAHULUAN

Artificial neural network (ANN) adalah salah satu metode machine learning yang sering digunakan untuk pemodelan atau prediksi. Pemodelan yang sering menggunakan ANN adalah pemodelan data kualitatif atau analisis data biner. ANN ini mampu memecahkan kasus nonlinier pada klasifikasi dan dapat memberikan akurasi yang tinggi [1]. Backpropagation neural network (BNN) adalah salah satu bagian dari ANN yang paling efektif untuk analisis data biner [2]. Namun BNN ini cenderung lambat untuk mencapai konvergen dalam mendapatkan akurasi yang optimum. Menurut Chen dan Su [3], algoritma resilient adalah salah satu algoritma terbaik pada BNN untuk mengatasi konvergensi yang lambat dan mampu mendapatkan akurasi yang tinggi. Hal tersebut telah dibuktikan oleh Kişi dan Uncuoğlu yang membandingkan algoritma conjugate gradient, Levenberg-Marquardt, dan resilient. Hasil analisis menunjukkan bahwa algoritma resilient BNN memberikan akurasi yang paling tinggi dari dua algoritma yang lain.

Berdasarkan uraian di atas, penelitian ini akan menerapkan metode BNN dengan algoritma resilient untuk mengoptimalkan akurasi dari prediksi financial distress dengan logistic regression (LR). Financial distress adalah suatu kondisi dari sebuah perusahaan yang mengalami kesulitan keuangan selama beberapa tahun berturut-

turut. Financial distress ini merupakan salah satu penyebab terbesar dari bankrutnya sebuah perusahaan [4]. Hasil prediksi financial distress dengan LR yang akan diperoleh, kemudian akurasi yang dihasilkan akan dioptimumkan dengan menggunakan algoritma resilient BNN.

II.METODE PENELITIAN

Penelitian ini menggunakan data financial distress yang berasal dari bursa efek Indonesia dengan respon berupa data biner, yaitu “1” untuk perusahaan yang mengalami financial distress dan “0” adalah untuk perusahaan yang tidak mengalami financial distress. Prediktor-prediktor yang diduga mempengaruhi terjadinya financial distress adalah 1) ukuran komite audit (X_1), 2) frekuensi pertemuan audit (X_2), 3) proporsi komite audit independen (X_3), 4) ukuran dewan direksi (X_4), 5) ukuran dewan komisaris (X_5), 6) kepemilikan manajerial (X_6), dan 7) kepemilikan institusional (X_7).

Penelitian ini akan menggunakan algoritma resilient BNN untuk mendapatkan akurasi yang lebih tinggi dari hasil prediksi financial distress dengan menggunakan LR. Resilient BNN merupakan salah satu metode dari ANN. ANN adalah metode *machine learning* yang menyerupai jaringan syaraf otak yang mempunyai bentuk yang fleksibel dan mampu menginterpretasi parameter-parameter yang tidak dapat dijelaskan pada model parametrik [5]. BNN merupakan bagian dari ANN yang sering disebut sebagai *supervised learning*. Metode ini merupakan salah satu metode yang sangat baik dalam menangani masalah pengenalan pola-pola kompleks. Pada jaringan *backpropagation*, setiap unit yang berada di *input layer* terhubung dengan setiap unit yang ada di *hidden layer*. Setiap unit yang ada di *hidden layer* terhubung dengan setiap unit yang ada di *output layer*. Pada jaringan *backpropagation* terdiri dari banyak lapisan (*multilayer network*) [6]. Jaringan *backpropagation* pada *training* terdapat tiga tahapan, yaitu:

1. Tahap *feedforward* pada *input*
2. Tahap perhitungan dan *backpropagation* dari error
3. Tahap *update* bobot dan bias.

Algoritma dari metode BNN adalah sebagai berikut.

Langkah 0 : Menentukan pembobot

Langkah 1 : Selama kondisi konvergen belum dicapai, maka melakukan langkah 2–9.

Langkah 2 : Setiap pasang pada data *training*, melakukan langkah 3-8.

Tahap *feedforward* :

Langkah 3 : Masing-masing unit pada input ($X_i, i:1,2,\dots,n$) diterima oleh *input layer* X_i dan diteruskan pada *hidden layer* ($Z_j, j:1,2,\dots,p$).

Langkah 4 : Masing-masing *hidden layer* menjumlahkan hasil pembobot pada *input layer* dan ditambahkan dengan bias.

Langkah 5 : Untuk setiap *output layer* ($Y_k, k:1,2,\dots,m$) dikalikan dengan bobot dan dijumlahkan serta ditambahkan dengan biasnya.

Backpropagation dari error :

Langkah 6 : Setiap *output layer* ($Y_k, k:1,2,\dots,m$) menerima pola target yang sesuai dengan pola *input* pada *training* dan menghitung error (δ_k) yang digunakan untuk mendapatkan bobot terkoreksi dan bias.

Langkah 7 : Setiap *hidden layer* ($Z_j, j:1,2,\dots,p$) menghitung (δ_j) kemudian digunakan untuk menghitung bobot terkoreksi dan bias antara *input* dan *hidden layer*.

Update pembobot dan bias :

Langkah 8 : Masing-masing *output layer* ($Y_k, k:1,2,\dots,m$) meng-*update* nilai pembobot dan bias ($j:1,2,\dots,p$) dan setiap *hidden layer* ($Z_j, j:1,2,\dots,p$) meng-*update* pembobot dan bias ($i:1,2,\dots,n$) sehingga mendapatkan pembobot dan bias yang baru.

Langkah 9 : Uji kondisi berhenti (sudah konvergen), maka iterasi berakhir

Pada tahapan untuk mendapatkan bobot akan menggunakan optimasi dengan algoritma resilient, karena konvergensi pada BNN berjalan lambat. Selain mampu mengatasi konvergensi yang lambat, resilient BNN mampu menghasilkan akurasi prediksi yang tinggi, dan estimasi parameter yang lebih akurat [3]. Model umum dari resilient BNN adalah:

$$o(\mathbf{x}) = w_0 + \sum_{j=1}^J w_j \cdot f \left(w_{0j} + \sum_{i=1}^p w_{ij} x_i \right)$$

dengan :

w_0 : *intercept* pada *output*

w_{0j} : *intercept* pada *hidden layer*

w_j : pembobot dari masing-masing *hidden layer* ke *output*

w_{ij} : pembobot dari masing-masing *input* ke *hidden layer*

$f(z)$: fungsi aktivasi

j : menyatakan banyaknya jumlah *hidden layer*

i : menyatakan banyaknya *input* yang digunakan

Pada optimasi ini yang pertama dilakukan adalah melakukan *update* dan mengontrol bobot pada setiap simpul. Dengan perubahan pembobot sebagai berikut:

$$\Delta w_{ij}^{(t)} = \begin{cases} -\Delta_{ij}^{(t)} & , \quad \text{jika } \frac{\partial E^{(t)}}{\partial w_{ij}} > 0 \\ \Delta_{ij}^{(t)} & , \quad \text{jika } \frac{\partial E^{(t)}}{\partial w_{ij}} < 0 \\ 0 & , \quad \text{untuk yang lain} \end{cases}$$

dengan $\frac{\partial E^{(t)}}{\partial w_{ij}}$ adalah jumlah nilai informasi gradient dari semua pola. Sebelum mendapatkan

update pembobot, maka terlebih dahulu mendapatkan nilai *update* terbaru $\Delta_{ij}^{(t)}$. Proses ini didasarkan pada adaptasi dependen seperti adaptasi pada *learning-rate*.

Dengan $\Delta_{ij}^{(t)}$ sebagai berikut :

$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ * \Delta_{ij}^{(t-1)} & , \quad \text{jika } \frac{\partial E^{(t-1)}}{\partial w_{ij}} * \frac{\partial E^{(t)}}{\partial w_{ij}} > 0 \\ \eta^+ * \Delta_{ij}^{(t-1)} & , \quad \text{jika } \frac{\partial E^{(t-1)}}{\partial w_{ij}} * \frac{\partial E^{(t)}}{\partial w_{ij}} < 0 \quad \frac{1}{2} \\ \Delta_{ij}^{(t-1)} & , \quad \text{untuk yang lain} \end{cases}$$

dimana $0 < \eta^- < \eta^+ < 1$. Algoritma dari optimasi *resilient* dapat dibagi menjadi dua bagian, yaitu bagian pertama tentang *step-size* seperti pada persamaan di atas. Jika $\frac{\partial E}{\partial w_{ij}}$ memiliki tanda yang sama pada iterasi yang berturut-turut maka *step-size*

meningkat. Sedangkan jika ada perubahan tanda, maka *step-size* menurun. *Step-size* ini dibatasi oleh parameter Δ_{\min} dan Δ_{\max} . Berikut adalah penjelasan kedua dari algoritma *resilient*, yaitu *update* bobot :

Langkah pertama : menentukan nilai awal dari ,

training dan testing dengan perbandingan 3:2. Langkah ini digunakan untuk mengetahui prediktor-prediktor yang berpengaruh terhadap terjadinya financial distress. Tabel 1 merupakan hasil dari analisis LR pada prediksi financial distress dan Tabel 2 merupakan akurasi dari hasil prediksi menggunakan LR.

Tabel 1. LR pada Prediksi Financial Distress

Variabel	Koefisien	SE	Wald	P	Odds ratio
X ₁	-1,296	0,640	4,104	0,043	0,274
X ₂	-0,240	0,072	11,164	0,001	0,786
X ₅ (1)	0,990	0,450	4,833	0,028	2,690
X ₇	2,450	0,953	6,603	0,010	11,588
Konstan	3,239	2,046	2,506	0,113	25,517

Tabel 2. Akurasi Pemodelan LR pada Prediksi Financial Distress

Actual	Prediction		Sum
	FD	Non FD	
FD	33	9	42
Non FD	19	23	42
Accuracy			66,67%

Berdasarkan Tabel 1 diketahui bahwa dari 7 prediktor yang diduga mempengaruhi kondisi financial distress pada 42 perusahaan di Indonesia hanya ada 4 yang berpengaruh signifikan, yaitu ukuran komite audit frekuensi pertemuan audit, ukuran dewan komisaris dan kepemilikan institusional (X₇). Hal ini ditandai dengan iterasi terakhir dari LR menunjukkan bahwa p-value dari keempat prediktor tersebut lebih kecil dari alpha sebesar 0.05. Berdasarkan prediktor yang signifikan pada Tabel 1 dapat terbentuk model LR untuk prediksi financial distress sebagai berikut.

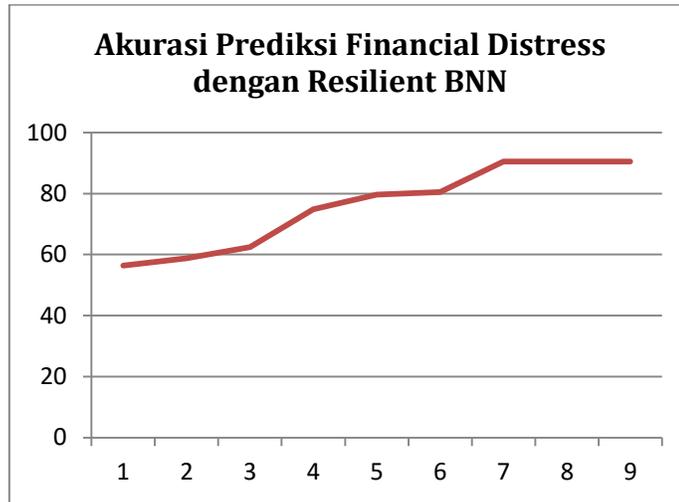
$$\pi(x_i) = \frac{\exp(3,239 - 1,296X_1 - 0,240X_2 + 0,990X_5 + 2,450X_7)}{1 + \exp(3,239 - 1,296X_1 - 0,240X_2 + 0,990X_5 + 2,450X_7)}$$

Tabel 2 menunjukkan hasil akurasi yang diperoleh dari prediksi financial distress menggunakan LR adalah sebesar 66.67%. Angka tersebut menunjukkan bahwa hasil prediksi kondisi *financial distress* yang tepat diklasifikasikan pada data aktual adalah sebesar 66,67%. Akurasi yang dihasilkan masih rendah, karena ada 33.33% hasil prediksi yang tidak sesuai dengan data aktualnya. Oleh karena itu akan digunakan resilient BNN untuk meningkatkan hasil akurasi dari prediksi financial distress agar model yang terbentuk dapat merepresentasikan kondisi financial distress.

Input yang digunakan pada resilient BNN ini berdasarkan hasil prediksi financial distress dengan menggunakan LR, yaitu hanya menggunakan empat prediktor signifikan. Simulasi ini dilakukan dengan menambahkan 1 *hidden layer* pada setiap kali *running*. Hasil simulasi resilient BNN untuk mendapatkan akurasi yang optimum dapat dilihat pada Tabel 3 dan Gambar 1.

Tabel 3. Hasil Simulasi pada Resilient BNN

Jumlah hidden layer	Akurasi	Error	Banyak Iterasi
1	56.45%	65.39	6428
2	58.79%	62.27	10472
3	62.44%	50.21	8266
4	74.82%	42.04	21244
5	79.66%	37.42	41529
6	80.44%	34.25	88066
7	90.48%	22.15	45346
8	98.48%	24.28	52678
9	90.48%	26.82	50281



Gambar 1. Akurasi Prediksi Financial Distress

Simulasi pada resilient BNN untuk mendapatkan akurasi yang optimum dilakukan dengan menggunakan fungsi aktivasi log-sigmoid. Fungsi aktivasi ini adalah yang paling sesuai, karena bentuk dari persamaan log-sigmoid memiliki kesamaan dengan model LR untuk data biner. Simulasi dilakukan dengan menambahkan 1 hidden layer untuk setiap kali running. Akurasi yang dihasilkan dari penggunaan 1 hidden layer sampai 9 hidden layer terus mengalami peningkatan dan error yang dihasilkan semakin menurun. Dengan kata lain, semakin banyak penggunaan hidden layer, maka akan menghasilkan akurasi yang lebih tinggi.

Titik optimum dari akurasi terletak pada penggunaan 7 hidden layer dan error yang dihasilkan adalah 22.15 dengan iterasi sebanyak 45346 kali. Akurasi yang dihasilkan yaitu sebesar 90.48%, sama seperti akurasi yang diperoleh pada penggunaan hidden layer sebanyak 8 dan 9. Namun, error yang dihasilkan pada penggunaan 7 hidden layer adalah yang paling rendah dari yang lainnya. Semakin kecil error yang dihasilkan, maka akan semakin baik hasil akurasi yang diperoleh. Berdasarkan hasil akurasi yang diperoleh diketahui bahwa hasil prediksi yang tidak tepat diklasifikasikan pada data aktualnya hanya 8.52%. Akurasi ini meningkat sebesar 23.81% dari hasil akurasi prediksi financial distress dengan menggunakan LR.

IV.PENUTUP

KESIMPULAN

Kesimpulan yang dapat diambil berdasarkan hasil analisis dari penelitaian yang telah dilakukan adalah faktor yang mempengaruhi kondisi financial distress pada 42 perusahaan adalah ukuran komite audit, frekuensi pertemuan komite audit, ukuran dewan komisaris dan kepemilikan institusional. Hasil simulasi akurasi dengan menggunakan resilient BNN optimum pada pennggunaan 7 hidden layer dengan hasil akurasi sebesar 90.48%. Akurasi yang dihasilkan meningkat sebesar 23.81% dari akurasi yang dihasilkan dengan LR, yaitu sebesar 66.67%.

DAFTAR PUSTAKA

- [1] Jiang, J., Zhang, J., Yang, G., Zhang, D., dan Zhang, L.2010. "Application of Backpropagation Neural Network in the Classification of High Resolution Remote Sensing Image: Take Remote Sensing Image of Beijing for Instance." In Proceedings of 18th International Conference on Geoinformatics, IEEE, 1-6.
- [2] Kişi, Özgür dan Uncuoğlu, Erdal. 2005. "Comparison of Three Back-Propagation Training Algorithms for Two Case Studies." In *Journal of Engineering and Materials Sciences*, 434-442.
- [3] Chen, Chien-Sheng dan Su, Szu-Lin. 2010. "Resilient Back-propagation Neural Network for Approximation 2-D GDOP." In Proceedings of the International Multi Conference of Engineers and Computer Scientists 2010, Vol II.
- [4] Elloumi, Fathi dan Gueyié, Jean-Pierre. 2001. "Financial Distress and Corporate Governance : An Empirical Analysis." In the International Journal of Business in Society, Vol. 1, No. 1, 15-23.

- [5] Suhartono. 2007. Feed Forward Neural Networks Untuk Pemodelan Runtun Waktu. Disertasi Program Doktorat Ilmu Matematika. Universitas Gadjah Mada, Yogyakarta.
- [6] Fausett, Lauren. 1994. Fundamental of Neural Networks: Architectures, Algorithms and Applications. 1st edition. Prentice Hall, New Jersey.
- [7] Riedmiller, M. dan Braun, H. 1993. "A Direct Adaptive method for Faster Backpropagation Learning : The RPROP Algorithm." In Proceedings of the IEEE International Conference on Neural Networks (ICNN), 586-591
- [8] Mushgil, Hanaa M., Alani, H. A., dan George, Loay E. 2015. "Comparison between Resilient and Standard Back Propagation Algorithms Efficiency in Pattern Recognition." In International Journal of Scientific & Engineering Research, Vol. 6, Issue 3, 773-778.