

STRUKTUR CORPORATE GOVERNANCE DAN KETEPATAN WAKTU PENYAMPAIAN LAPORAN KEUANGAN: PERBANDINGAN MODEL LOGISTIK DAN NEURAL NETWORK

Tri Gunarsih

Jurusan Manajemen Fakultas Ekonomi UTY
Jl. Glagahsari No.63 Yogyakarta

Abstract: *The main objective of this study was to examine the impact of corporate governance structure and the performance of the firms to timelines in Indonesian Stock Exchange using two alternative methods, Logistic Regression and Neural Network. This study combined corporate governance structure and timelines study. Samples in this study were public companies listed in Indonesian Stock Exchange. The dependent variable was timelines proxied by dummy variable, 1 if companies published financial reporting before 120 days after December 31 and 0 otherwise. Governance structures are proxied number of the Board of Directors and number of the Board of Commissioners. The results of the study showed that the prediction accuracy of logistic regression is 61.2% while Neural Network is more than 96%. This suggested that Neural Network predicts more accurately than logistic regression.*

Key words: corporate governance structure, timelines, financial performance, neural network

Penelitian ini merupakan lanjutan dari Gunarsih & Hartadi (2008), yang meneliti mengenai analisis struktur Corporate Governance (CG) dan ketepatan waktu penyampaian laporan keuangan dengan menggunakan metode regresi logistik. Penelitian ini dengan menggunakan sumber data yang sama, mengkomparasikan analisis regresi logistik dengan metode Neural Network (NN).

NN atau Jaringan saraf tiruan merupakan sebuah model matematis atau model komputasi yang mencoba mensimulasikan struktur dan atau aspek fungsional dari jaringan syaraf biologis.

Jaringan ini terdiri dari sebuah kelompok yang saling berhubungan dari *neuron* buatan. Fungsi NN untuk penelitian antara lain bisa dikategorikan ke dalam 3 kelompok utama (Wikipedia), yaitu (1) analisis regresi, meliputi prediksi data runtun waktu dan pemodelan, (2) pengklasifikasian, meliputi pola dan penentuan urutan, deteksi baru serta pengambilan keputusan sekuensial, dan (3) pemrosesan data (*data processing*).

Dalam praktek bisnis, NN bisa diimplementasikan pada kelompok bidang akuntansi, keuangan, sumberdaya manusia dan pemasaran

(Bhargava & Gupta). Khususnya dalam bidang keuangan, NN bisa diimplementasikan antara lain dalam bidang *underwriting mortgage*, peramalan tingkat pertukaran mata uang asing, prediksi *Initial Public Offering*, prediksi kebangkrutan perusahaan maupun manajemen risiko.

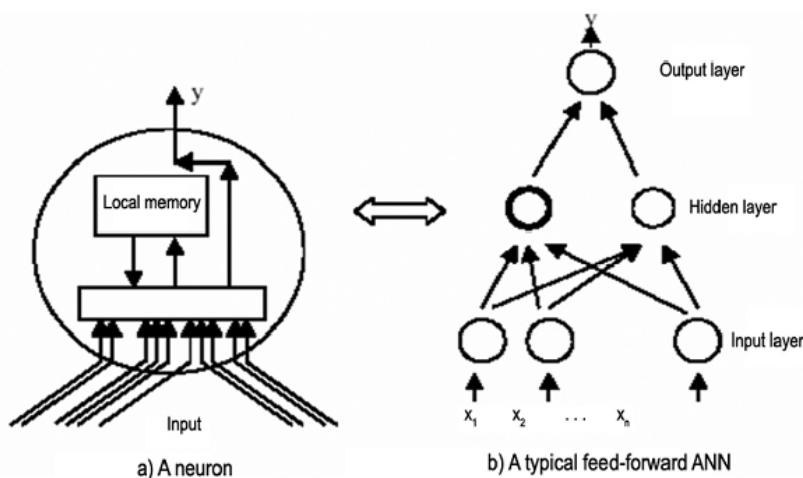
Penelitian ini melengkapi penelitian NN sebelumnya, yaitu implementasi NN dalam memprediksi ketepatan waktu dalam penyampaian laporan keuangan. Pertanyaan penelitian utama adalah: apakah NN lebih akurat dalam memprediksi ketepatan waktu penyampaian laporan keuangan oleh perusahaan publik dibandingkan dengan regresi logistik?

PENGERTIAN NEURAL NETWORK SECARA SINGKAT

NN atau Jaringan Syaraf Tiruan adalah adalah kelompok saling terkait dari alam atau *neuron* buatan yang menggunakan model matematis atau komputasi untuk pemrosesan informasi

berdasarkan *connectionistic* pendekatan perhitungan. Dalam kebanyakan kasus, NN adalah sebuah sistem adaptif, yang merubah struktur berdasarkan informasi eksternal maupun internal yang mengalir melalui jaringan (Wikipedia).

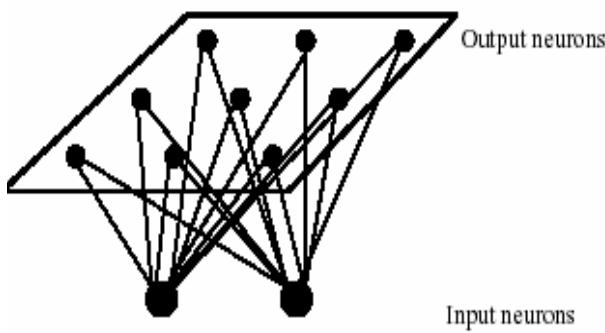
Bhargava & Gupta menjelaskan bahwa NN meniru cara kerja *neuron* manusia dan bekerja mendasarkan pada stimulus dunia luar. NN yang menggunakan *artificial intelligence* dinamakan *Artificial Neural Network* (ANN). ANN terdiri dari banyak prosesor tunggal, yang berinteraksi melalui jaringan interkoneksi padat. Neuron atau *Processing Element* (PE) melakukan 2 hal utama. Pertama, menghitung *output*, yang dikirimkan ke PE lain atau di luar jaringan. Neuron atau PE menentukan nilai *output* dengan mengaplikasikan fungsi transfer. Kedua, melakukan *update* memori lokal, yaitu bobot atau tipe lain dari data, disebut variabel data. Neuron mengorganisasikan data melalui *layer*. Layer pertama disebut *layer input* dan layer terakhir disebut *layer output* sedangkan *inner layer*, satu atau lebih, disebut sebagai *hidden layer* (Gambar 1).



Sumber: Bhargava dan Gupta

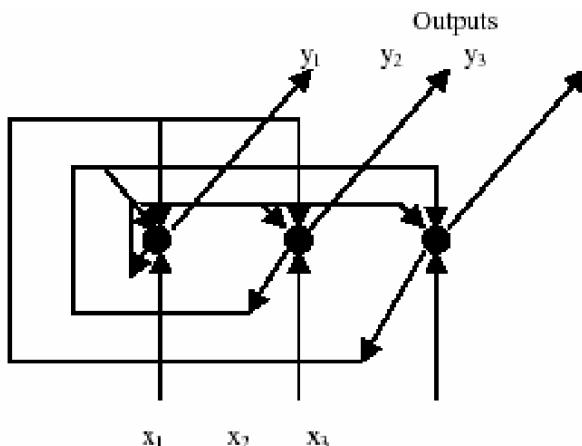
Gambar 1. A Neuron and Artificial Neural Network

Dari beberapa jenis arsitektur ANN yang ada, dua diantaranya adalah *multi-layer perceptron*, *Self-Organising Map (SOM)* dari Kohonen dan *Hopfield network*. Tipe pertama pada dasarnya jejaring ke depan karena mengirim *output* ke neuron berikutnya, sedangkan tipe kedua adalah aliran ke belakang.



Sumber: Bhargava dan Gupta

Gambar 2. Self-Organizing Maps dari Kohonen



Sumber: Bhargava dan Gupta

Gambar 3. Hopfield Network

IMPLEMENTASI NEURAL NETWORK PADA RISET BISNIS

Salah satu implementasi NN pada riset bisnis adalah deteksi *fraud*, yaitu prediksi *fraud* pada pembayaran kartu kredit (Bhargava & Gupta). Dengan transaksi sebanyak 400.000 per hari, terjadi 2,5% *fraud* menghilangkan keuntungan sebesar satu juta dolar per hari. Namun demikian, kejahatan kartu kredit sulit untuk ditentukan jumlahnya. Salah satu penyebabnya adalah kekhawatiran perusahaan, jika mengumumkan jumlah kejahatan kartu kredit akan memberikan rasa takut pada publik. Penyebab yang lain adalah karena angka kejahatan selalu berubah sepanjang waktu. Leonard (1993) dalam Bhargava & Gupta memperkirakan biaya kejahatan kartu kredit dari Visa/Mastercard di Canada tahun 1989, 1990 dan 1991 berturut-turut adalah 19, 29 dan 46 juta dolar Canada.

Kejahatan (*fraud*) dalam aplikasi terjadi apabila seseorang mendapatkan kartu kredit baru tetapi menggunakan informasi pribadi yang keliru atau palsu. Hand & Henley (1997) dalam Bhargava & Gupta menggunakan *scorecard* kredit tradisional untuk mendeteksi konsumen yang akan gagal bayar dengan salah satu kemungkinan penyebabnya adalah *fraud*. *Scorecards* tersebut mendasarkan pada informasi detail dari aplikasi pendaftaran dan juga informasi lain, misalnya dari biro informasi. Beberapa peneliti menggunakan NN untuk mendeteksi *fraud* pada kartu kredit, diantaranya Ghosh & Reilly (1994), Aleskerov, et al.(1997), Dorronsoro (1997), dan Brause (1999) dalam Bhargava & Gupta. Deteksi dengan NN tersebut, terutama dalam konteks klasifikasi supervisi.

Penggunaan NN lain adalah implementasi pada peningkatan *return* saham, yang dilakukan oleh Quah & Srinivasan. Dengan data saham Singapura, mereka mengembangkan ANN untuk memilih saham. Dengan menggunakan data historis, ANN mampu memilih saham yang memiliki kinerja. Kinerja saham tercermin dalam profitabilitas dan kualitas manajemen perusahaan yang mengeluarkan saham.

Implementasi NN lain adalah dalam prediksi kebangkrutan perusahaan. Kim & Jun melakukan penelitian dengan membandingkan data akuntansi dengan data pasar dalam memprediksi kebangkrutan perusahaan menggunakan NN. Hasil penelitian menunjukkan bahwa kedua data tersebut memberikan informasi yang berguna bagi kebangkrutan perusahaan. Hal lain yang menarik, dengan menggunakan kedua jenis data tersebut secara bersama-sama dapat meningkatkan akurasi ketepatan prediksi. Penelitian lain, misalnya dilakukan oleh Perez, yang mengimplementasikan ANN dalam memprediksi kebangkrutan perusahaan.

KOMPARASI NEURAL NETWORK DENGAN METODE LAIN

Beberapa penelitian dalam prediksi kebangkrutan perusahaan mengkomparasikan NN dengan metode statistik. Mayoritas hasil penelitian menunjukkan bahwa NN lebih unggul dibandingkan dengan metode statistik dalam memprediksi kebangkrutan perusahaan.

Salah satu penelitian dilakukan oleh Back, Laitinen, Sere, & Wezel (1996). Mereka mengkomparasikan analisis diskriminan, analisis logit dan *genetic algoritma*. Akurasi prediksi model diuji dengan pendekatan statistik untuk diskriminan

dan logit sedangkan genetik algoritma diuji menggunakan NN. Hasil penelitian menunjukkan bahwa NN lebih unggul dibandingkan dua metode yang lain untuk prediksi 3 tahun sebelum kebangkrutan. Untuk pengujian 2 tahun sebelum kebangkrutan, analisis diskriminan memiliki tingkat kesalahan terendah.

Penelitian lain dilakukan oleh Hu & Tseng (2005). Mereka mengaplikasikan *backpropagation* NN menggunakan *multi-layer perceptron* dan *radial basis function network* dalam memprediksi kebangkrutan perusahaan. Hasil penelitian menggunakan perusahaan bangkrut dan tidak bangkrut di Inggris menunjukkan bahwa *radial basis function network* lebih unggul dibandingkan metode klasifikasi lain, termasuk *multi-layer perceptron*, analisis diskriminan, dan metode probit.

KETEPATAN WAKTU PENYAMPAIAN LAPORAN KEUANGAN

Setiap perusahaan harus memastikan bahwa asas GCG diterapkan pada setiap aspek bisnis dan di semua jajaran perusahaan. Asas GCG yaitu transparansi, akuntabilitas, responsibilitas, independensi serta kewajaran dan kesetaraan diperlukan untuk mencapai kesinambungan usaha (*sustainability*) perusahaan dengan memperhatikan pemangku kepentingan (KNKG, 2006). Dari paparan tersebut, transparansi adalah salah satu asas dari GCG, sebagaimana OECD (1999) maupun FCGI (2000). Lebih lanjut KNKG (2006) memberikan pedoman dasar dari transparansi, yaitu: Untuk menjaga obyektivitas dalam menjalankan bisnis, perusahaan harus menyediakan informasi yang material dan relevan dengan cara yang mudah diakses dan dipahami oleh pemangku kepentingan. Perusahaan harus mengambil

inisiatif untuk mengungkapkan tidak hanya masalah yang disyaratkan oleh peraturan perundang-undangan, tetapi juga hal yang penting untuk pengambilan keputusan oleh pemegang saham, kreditur dan pemangku kepentingan lainnya. Salah satu pedoman pelaksanaan transparansi dari KNKG (2006) adalah bahwa perusahaan harus menyediakan informasi secara tepat waktu, memadai, jelas, akurat dan dapat diperbandingkan serta mudah diakses oleh pemangku kepentingan sesuai dengan haknya.

Laporan keuangan adalah salah satu informasi yang material dan relevan untuk pengambilan keputusan oleh pemegang saham, kreditur maupun pemangku kepentingan (*stakeholders*) yang lain. Dengan demikian, sebagaimana asas transparansi, laporan keuangan harus disampaikan secara tepat waktu, memadai, jelas, akurat dan dapat diperbandingkan.

Studi mengenai ketepatan waktu penyampaian laporan keuangan (*timelines*) sudah banyak dilakukan, tetapi hanya menganalisis kinerja keuangan, baik mendasarkan pada nilai buku maupun nilai pasar. Misalnya, Dyer & Mchugh (1975) dengan data perusahaan Australia tahun 1965-1971, Courtis (1976) dengan data perusahaan New Zealand serta Davies & Whittred (1980), menemukan bahwa terdapat hubungan negatif antara keterlambatan waktu pelaporan dengan ukuran perusahaan. Berbeda dengan Dyer & Mchugh (1975) yang menemukan bahwa keterlambatan tidak berhubungan dengan profitabilitas, Courtis (1976) menemukan bahwa terdapat hubungan yang terbalik, meskipun bersifat sementara dan tergantung pada ukuran profitabilitas yang digunakan. Analisis ketepatan waktu dan kinerja pasar menggunakan *abnormal return* dilakukan antara lain oleh Givoli & Palmon (1982), Kross (1982), Chambers & Penmann (1984).

Mereka menemukan bahwa pengumuman yang lebih cepat (lambat) berhubungan dengan *abnormal return* yang lebih tinggi (rendah), atau variabilitas *return* yang tinggi (rendah) relatif terhadap laporan yang terlambat (lebih cepat).

Penelitian di Indonesia, misalnya oleh Wiwik (1996) meneliti faktor-faktor yang mempengaruhi keterlambatan penerbitan laporan keuangan perusahaan publik. Hasil penelitian menunjukkan bahwa tingkat profitabilitas mempengaruhi kecukupan penerbitan laporan keuangan. Naim (1999) menguji ketidakpatuhan perusahaan terhadap peraturan ketepatan waktu penyampaian laporan keuangan perusahaan publik dengan variabel penjualan, *return on assets* (ROA), *return on equity* (ROE) dan pertumbuhan profit. Hasil penelitian menunjukkan bahwa hanya *return on assets* (ROA) yang berpengaruh secara signifikan. Analisis dengan kinerja pasar misalnya dilakukan oleh Priyastiwi (2002). Hasil penelitian menunjukkan bahwa laba *abnormal* secara signifikan mempengaruhi keterlambatan laporan keuangan. Semakin tinggi laba tidak normal, semakin tinggi kemungkinan perusahaan tidak terlambat menyajikan laporan keuangan.

Penelitian lain dilakukan oleh Gunarsih & Hartadi (2008) dengan sampel perusahaan jasa. Berbeda dengan penelitian sebelumnya, Gunarsih & Hartadi (2008) memasukkan variabel struktur *corporate governance* dalam memprediksi ketepatan waktu penyampaian laporan keuangan. Hasil penelitian menunjukkan bahwa struktur *corporate governance* berpengaruh negatif terhadap ketepatan penyampaian laporan keuangan. Hal ini mengindikasikan bahwa semakin sedikit jumlah Dewan Direksi, semakin tepat dalam penyampaian laporan keuangan. Variabel kinerja perusahaan yang berhubungan dengan probabilitas ketepatan waktu penyampaian

Laporan keuangan adalah ROI. Semakin tinggi ROI, semakin tinggi probabilitas ketepatan penyampaian laporan keuangan perusahaan jasa.

METODE

Sampel penelitian adalah sebagaimana Guinarsih & Hartadi (2008), yaitu perusahaan publik dari data sekunder tahun 2007, tetapi tanpa membedakan jenis industri dan dipilih dengan *purposive*.

Variabel penelitian yang dipergunakan dalam penelitian ini berasal dari data sekunder. Definisi operasional masing-masing variabel dimaksud adalah sebagai berikut: proksi struktur *corporate governance* adalah jumlah dewan komisaris dan jumlah dewan direksi (J_KOM dan J_DIR). Variabel ini diperlukan untuk mengamati secara lebih seksama pengaruh dewan pada masing-masing perusahaan sebagai mekanisme internal *corporate governance* terhadap kinerja perusahaan.

Kinerja keuangan perusahaan diukur dengan rasio keuangan perusahaan, yaitu profitabilitas dengan proksi *return on investment* (ROI), *return on equity* (ROE) dan laba bersih (EAT).

Ketepatan waktu penyampaian laporan keuangan menggunakan variabel *dummy*, 1 untuk perusahaan yang tidak terlambat menyampaikan laporan (maksimal 120 hari sejak tanggal 31 Desember) dan 0 sebaliknya.

Variabel kontrol yang digunakan adalah pertumbuhan penjualan (*sales growth* atau SG), total aset dan total penjualan. Pertumbuhan penjualan mengukur kondisi permintaan perusahaan. Pada perusahaan dengan pertumbuhan pasar relatif cepat, diharapkan mempunyai peng-

lamana profitabilitas di atas rata-rata. Variabel pertumbuhan penjualan dari tahun ke tahun diukur dalam:

$$\frac{\text{Penjualan}_{it} - \text{Penjualan}_{i,t-1}}{\text{Penjualan}_{it-1}}$$

$$\text{atau } \frac{\text{Penjualan}_{it}}{\text{Penjualan}_{it-1}} - 1$$

Penjualan_{it} adalah penjualan perusahaan i pada tahun t. Penjualan_{it-1} adalah penjualan perusahaan i pada tahun t-1 atau satu tahun sebelumnya. Data laporan keuangan dan data perusahaan diperoleh dari *Indonesian Capital Market Directory* (ICMD). Data keterlambatan waktu penyampaian laporan keuangan diperoleh dari Pusat Referensi Pasar Modal (PRPM) Bursa Efek Indonesia.

Untuk menganalisis pengaruh struktur corporate governance dan kinerja keuangan terhadap ketepatan waktu penyampaian laporan keuangan digunakan model regresi logistik sebagai berikut.

Keterangan:

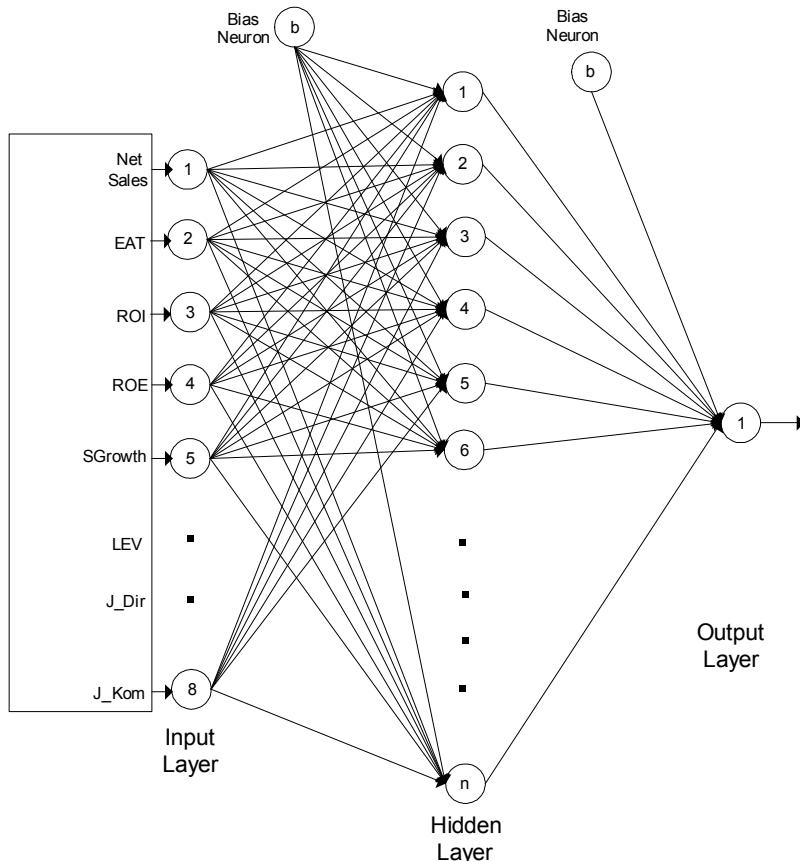
- | | |
|---------|--|
| KW | = Ketepatan waktu penyampaian laporan keuangan perusahaan i waktu t, 1 untuk perusahaan yang tidak terlambat dan 0 sebaliknya. |
| ROI | = <i>Return on Investments</i> |
| ROE | = <i>Return on Equity</i> |
| SGROWTH | = <i>Sales growth</i> |
| LEV | = <i>Leverage</i> |

JUM_KOM	=	Jumlah Dewan Komisaris
JUM_DIR	=	Jumlah Dewan Direksi
TA	=	Total Aset
N_SALES	=	Total Penjualan
EAT	=	Laba bersih setelah pajak (<i>earning after tax</i>)
u	=	nilai residual.

Neural Network

Penelitian ini terdiri dari 3 langkah, yaitu: (1) menyiapkan data penelitian, yang terdiri dari 3 kelompok yaitu ketepatan waktu penyampaian laporan keuangan, kinerja keuangan perusahaan serta struktur *corporate governance*; (2) Mengembangkan *software* untuk mensimulasikan *back propagation neural network* dengan momentum dan *adaptive learning rate*. Simulasi dilakukan dengan menggunakan *neural network toolbox matlab*. Gambar 4 menjelaskan topologi dari *neural network* dan Tabel 1 memaparkan parameter yang dipergunakan dalam penelitian. *Neural Network* terdiri dari 3 layer, yaitu *layer input* yang menerima data kinerja keuangan dan struktur *corporate governance*, *hidden layer* yang menghitung data tersebut, dan *layer output* yang mengidentifikasi kelompok perusahaan, yaitu kelompok yang tepat dalam menyampaikan laporan keuangan serta kelompok yang tidak tepat dalam menyampaikan laporan keuangan.

propagation neural network dengan momentum dan *adaptive learning rate*. Simulasi dilakukan dengan menggunakan *neural network toolbox matlab*. Gambar 4 menjelaskan topologi dari *neural network* dan Tabel 1 memaparkan parameter yang dipergunakan dalam penelitian. *Neural Network* terdiri dari 3 layer, yaitu *layer input* yang menerima data kinerja keuangan dan struktur *corporate governance*, *hidden layer* yang menghitung data tersebut, dan *layer output* yang mengidentifikasi kelompok perusahaan, yaitu kelompok yang tepat dalam menyampaikan laporan keuangan serta kelompok yang tidak tepat dalam menyampaikan laporan keuangan.



Gambar 4. Topologi Neural Network

Tabel 1. Parameter Neural Network

Input neurons	: 8
Hidden neurons	: 20, 25, 30
Output neurons	: 1
Initial learning rate	: 0,9
Momentum	: 0,9
Sum Square Error (SSE)	: 0,1

Setelah data dan software *simulator neural network* siap, *neural* dilatih (*trained*) dengan *hidden neurons* yang berbeda-beda. Pelatihan (*training*) dilakukan pada 245 sampel yang digunakan. Sebanyak 133 sampel adalah perusahaan yang tidak tepat dalam menyampaikan laporan keuangan (kode 0) dan sebanyak 112 sampel adalah perusahaan yang tepat dalam menyampaikan laporan keuangan (kode 1). Pada masing-masing pelatihan (*training*), akurasi dari masing-masing klasifikasi dicatat.

HASIL

Statistik Deskriptif

Tabel 2 memaparkan statistik deskriptif dari data yang dipergunakan dalam penelitian. Total data adalah 245, yang dipilih dari Gunarsih & Hartadi (2008). Tidak semua data yang dipergunakan oleh Gunarsih & Hartadi (2008) dianalisis karena metode *Neural Network* mensyaratkan jumlah mendekati proporsi sama untuk kelompok perusahaan yang terlambat dan yang tidak terlambat dalam menyampaikan laporan keuangan.

Tabel 2. Statistik Deskriptif

Variabel	Keterangan	N	Minimum	Maximum	Mean
TA	Total asset	245	306	48.042.327	2.370.955,34
N_SALES	Net sales	245	704	23.137.376	1.219.775,71
EAT	Earning after Taxes	245	-7002005	2.276.632	-8.395,70
ROI	Return On Investment	245	-29,43	113,94	2,1257
ROE	Return On Equity	245	-1429,87	299,14	-8,0876
SGROWTH	Sales growth	245	-0,82	196,80	1,1798
LEV	Leverage	245	0,00	2,27	0,6315
J_DIR	Jumlah direksi	245	2	14	4,82
J_KOM	Jumlah komisaris	245	2	10	4,31
KW	Ketepatan waktu	245	0	1	0,50
	Valid N (listwise)	245			

Sumber: Data sekunder, diolah (2009).

Pengujian Model Regresi Logistik

Model regresi logistik pertama yang diuji adalah sebagai berikut.

$$KW_{it} = \beta_1 + \beta_2 ROI_{it} + \beta_3 ROE_{it} + \beta_4 SGROWTH_{it} + \beta_5 LEV_{it} + \beta_6 J_DIR_{it} + \beta_7 J_KOM_{it} + \beta_8 TA_{it} + \beta_9 N_SALES_{it} + \beta_{10} EAT_{it} + u_i$$

Tabel 3. Jumlah Sampel Pengujian Regresi Logistik

Unweighted Cases(a)		N	Percent
Selected Cases	Included in Analysis	245	100.0
	Missing Cases	0	.0
	Total	245	100.0
Unselected Cases		0	.0
Total		245	100.0

Sumber: Data sekunder, diolah (2009).

Goodness of fit test (model fit)

Model *fit* dipergunakan untuk menguji *overall fit* model terhadap data. Hipotesis untuk menguji model *fit* adalah sebagai berikut.

H_0 : Model yang dihipotesiskan *fit* dengan data

H_A : Model yang dihipotesiskan tidak *fit* dengan data.

Pengujian hipotesis bahwa data empiris cocok atau sesuai dengan model (tidak ada perbedaan antara model dengan data sehingga model dapat dikatakan *fit*) dilakukan dengan pengujian *Hosmer and Lemeshow's goodness of fit*. Jika nilai *Hosmer and Lemeshow's goodness of fit test statistics* sama dengan atau kurang dari 0,05 maka hipotesis nol ditolak yang berarti ada perbedaan signifikan antara model dengan nilai observasinya *goodness of fit* tidak baik karena model tidak dapat memprediksi nilai observasinya (Ghozali, 2001).

Tabel 4. Contingency Table for Hosmer and Lemeshow Test

Step 1	Prediksi = 0		Prediksi = 1		Total
	Observed	Expected	Observed	Expected	
1	22	18.285	3	6.715	25
2	18	16.252	7	8.748	25
3	15	15.279	10	9.721	25
4	15	14.675	10	10.325	25
5	15	14.114	10	10.886	25
6	9	13.612	16	11.388	25
7	13	12.855	12	12.145	25
8	10	11.973	15	13.027	25
9	8	10.698	17	14.302	25
10	8	5.260	12	14.740	20

Sumber: Data sekunder diolah, 2009.

Tabel 5. Hosmer and Lemeshow's

Step	Chi-square	df	Sig.
1	10.691	8	.220

Sumber: Data sekunder diolah, 2009.

Jika nilai statistik *Hosmer and Lemeshow's goodness of fit* lebih besar dari 0,05 maka hipotesis nol tidak dapat ditolak dan berarti model mampu memprediksi nilai observasinya atau dapat dikatakan bahwa model dapat diterima karena cocok dengan observasinya. Dari hasil analisis didapatkan keluaran sebagaimana Tabel 4 dan 5. Hasil analisis menunjukkan bahwa nilai statistik *chi-square Hosmer and Lemeshow's goodness of fit* adalah 10,691 dengan probabilitas signifikansi 0,220 (tabel 5) yang nilainya jauh di atas 0,05. Dengan demikian dapat disimpulkan bahwa model (1) dapat diterima karena probabilitas signifikansi jauh di atas 0,05.

Ketepatan Estimasi

Nilai estimasi yang benar (*correct*) dan salah (*incorrect*) dapat diuji dengan mempergunakan tabel klasifikasi 2x2. Angka kolom pada tabel klasifikasi merupakan dua nilai prediksi dari variabel dependen dalam hal ini adalah ketepatan penyampaian laporan keuangan (1) dan ketidak-tepatan (0). Angka pada baris menunjukkan nilai observasi sesungguhnya dari variabel dependen. Pada model yang sempurna, maka semua kasus akan berada pada diagonal dengan tingkat ketepatan peramalan 100%. Hasil klasifikasi nilai observasi dan prediksi adalah sebagaimana Tabel 6.

Tabel 6. Klasifikasi Nilai Observasi dan Prediksi

Step	Prediksi	Observed		Predicted	
				Prediksi	Percentage Correct
		0	1		
Step 1	Prediksi	0	106	27	79.7
		1	68	44	39.3
	Overall Percentage				61.2

Sumber: Data sekunder diolah, 2009.

Hasil analisis menunjukkan bahwa pada baris jumlah perusahaan yang tidak tepat dalam penyampaian laporan keuangan dan diprediksi dengan benar (tidak tepat) adalah 106 sedangkan jumlah diprediksikan dengan tidak benar (tepat dalam penyampaian laporan keuangan) adalah sejumlah 27 perusahaan. Dengan demikian, persentase ketepatan prediksi baris ini adalah sebesar 79,7%. Pada baris jumlah perusahaan yang tepat dalam penyampaian laporan keuangan dan diprediksikan dengan benar (tepat dalam penyampaian laporan keuangan) adalah 44 sedangkan jumlah diprediksikan dengan tidak benar (tidak tepat dalam penyampaian laporan keuangan) adalah sejumlah 68 perusahaan. Dengan demikian, persentase ketepatan prediksi adalah sebesar 39,3%. Secara keseluruhan, persentase ketepatan model dalam memprediksi ketepatan waktu penyampaian laporan keuangan adalah sebesar 61,2%.

Estimasi Parameter dan Interpretasi

Tabel 7. Estimasi Parameter Model

	B	S.E.	Wald	Df	Sig.
Step 1(a) TA	.000	.000	.235	1	.628
NET_SL	.000	.000	.315	1	.574
EAT	.000	.000	.500	1	.480
ROI	.000	.001	.190	1	.663
ROE	.001	.002	.289	1	.591
SGROWTH	1.065	.378	7.949	1	.005
LEV	-.197	.265	.551	1	.458
J_DIR	.107	.084	1.655	1	.198
J_KOM	-.077	.105	.548	1	.459
Constant	-.455	.471	.932	1	.334

Sumber: Data sekunder diolah, 2009.

Hasil analisis untuk estimasi parameter model menunjukkan bahwa terdapat 1 variabel yang berhubungan dengan ketepatan waktu dalam penyampaian Laporan keuangan, yaitu SGROW (pertumbuhan penjualan, yang signifikan secara statistis pada $\alpha 1\%$).

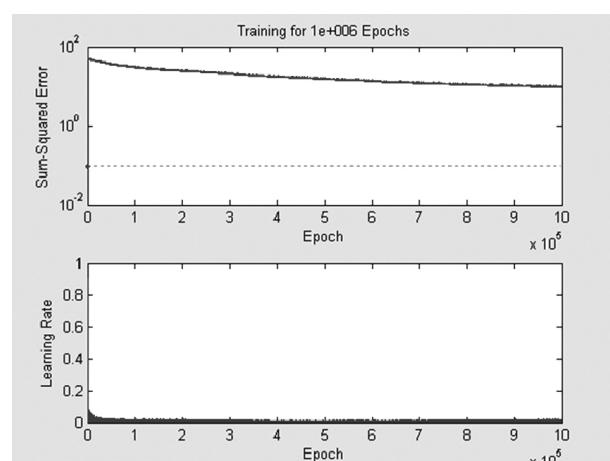
bahwa sampai dengan 1.000.000 *iteracy, neural network* mampu mengklasifikasikan perusahaan dengan tingkat akurasi lebih dari 96%. Gambar 5, 6 , dan 7 memaparkan proses *training* dengan 20, 25 dan 30 *neurons*.

Pengujian Neural Network

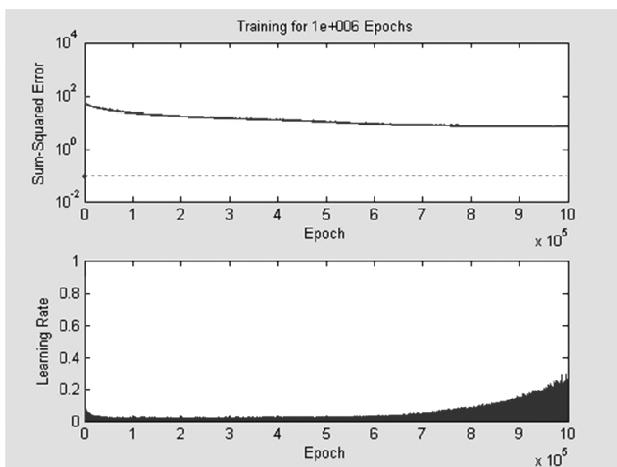
Tabel 8. Hasil Training Neural Network

Iteration (Max): 1.000.000	Number of Hidden Neurons		
	20	25	30
SSE	9,3944	7,0895	9,058
Accuracy,	96,3%	97,95	97,1%
Error (firm type)	1=6, 0=3	1=5, 0=0	1=7, 0=0

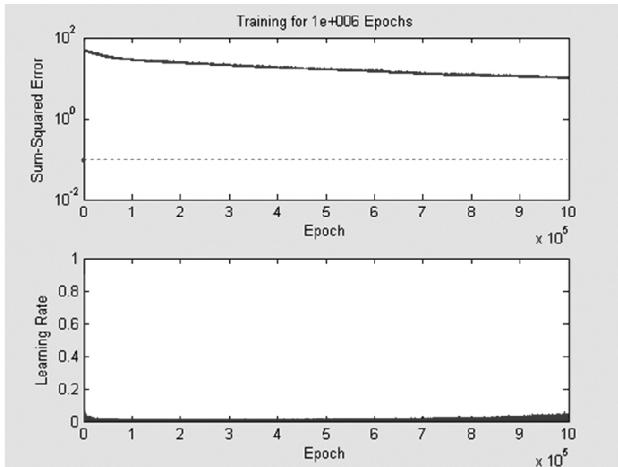
Tabel 8 memaparkan hasil dari *training neural network*. Hasil pada Tabel 8 menunjukkan



Gambar 5. Training Process with 20 Hidden Neurons



Gambar 6. Training Process with 25 Hidden Neurons



Gambar 7. Training Process with 30 Hidden Neurons

PEMBAHASAN

Penelitian ini merupakan kelanjutan dari Gunarsih & Hartadi (2008), yaitu dengan menggunakan sumber data yang sama, analisis regresi

logistik kemudian dikomparasikan dengan *neural network*. Jumlah data yang dipergunakan dalam analisis neural network dan regresi logistik adalah sama yaitu 245.

Hasil analisis pada model regresi logistik memiliki angka ketepatan prediksi sebesar 61,2% sedangkan hasil neural network menunjukkan ketepatan prediksi lebih dari 96%. Hal ini menunjukkan bahwa model *neural network* memiliki ketepatan pengklasifikasian dibandingkan dengan regresi logistik.

Hasil penelitian ini mendukung temuan sebelumnya dalam hal mengkomparasikan model *neural network* dengan pendekatan statistik, diantaranya Tam & Kiang (1992) dalam Kim dan Jun, et al. (1996), Hu & Tseng (2005) serta Hsieh, et al. Tam & Kiang (1992) mengevaluasi risiko kebangkrutan mendasarkan rasio keuangan dengan membandingkan *neural network* dan metode statistik. Hasil penelitian tersebut menunjukkan bahwa *neural network* memiliki akurasi prediksi dibandingkan analisis diskriminan maupun logit. Penelitian lain oleh Back, et al. (1996) yang mengkomparasikan analisis diskriminan, analisis logit dan genetik algoritma. Hasil penelitian menunjukkan bahwa NN lebih unggul dibandingkan dua metode yang lain untuk prediksi 3 tahun sebelum kebangkrutan. Hu & Tseng (2005) yang memprediksi kebangkrutan perusahaan juga menunjukkan bahwa *radial basis function network* lebih unggul dibandingkan metode klasifikasi lain, termasuk *multi-layer perceptron*, analisis diskriminan, dan metode probit. Hsieh, et al. dengan menggunakan data Taiwan juga menunjukkan bahwa *hybrid neural network* memiliki tingkat akurasi lebih tinggi dibandingkan modal MDA.

KESIMPULAN DAN SARAN

Kesimpulan

Penelitian ini mengkomparasikan analisis regresi logistik dengan *neural network* (NN) dalam memprediksi ketepatan waktu penyampaian laporan keuangan oleh perusahaan publik dengan data prediksi kinerja keuangan perusahaan serta struktur *corporate governance* mendasarkan pada Gunarsih & Hartadi (2008). NN atau jaringan syaraf merupakan model matematis atau komputasi yang mensimulasikan struktur dan aspek fungsional dari jaringan syaraf biologis. Salah satu manfaat dari NN adalah dapat dimanfaatkan untuk pengklasifikasian data, sebagaimana yang digunakan dalam penelitian ini.

Hasil analisis menunjukkan bahwa hasil analisis pada model regresi logistik memiliki angka ketepatan prediksi sebesar 61,2% sedangkan hasil NN menunjukkan ketepatan prediksi lebih dari 96%. Hal ini menunjukkan bahwa model NN memiliki ketepatan pengklasifikasian lebih tinggi dibandingkan dengan regresi logistik.

Saran

Model NN merupakan model alternatif dari model statistik dalam penelitian bidang keuangan. Hasil penelitian ini serta beberapa penelitian lain menunjukkan bahwa model NN lebih unggul dibandingkan model statistik sehingga untuk penelitian berikutnya disarankan untuk menggunakan metode NN sebagai alternatif lain. Penelitian ini hanya menggunakan sampel pada perusahaan jasa. Penelitian berikutnya bisa dilakukan dengan menambahkan perusahaan manufaktur ataupun mengkomparasikan perusahaan

jasa dengan manufaktur, terutama untuk menguji konsistensi hasil penelitian.

DAFTAR PUSTAKA

- Back, B., Laitinen, T., Sere, K., & Wezel, M. 1996. Choosing Bankruptcy Predictors Using Discriminant Analysis, Logit Analysis, and Genetic Algorithms.
- Bhargava, N. & Gupta, M. *Application of Neural Network in Business Applications*. <http://www.nikhilbhargava.com/papers/lahore.pdf> . Di-download Agustus 2008.
- Chambers, A.E. & Penman, S.H. 1984. Timeliness of Reporting and The Stock Price Reaction to Earning Announcement. *Journal of Accounting Research*, Spring, pp.21-47.
- Curtis, J.K. 1976. Relationship between Timeliness in Corporate Reporting and Corporate Attributes. *Accounting and Business Research*, Winter, pp.45-156.
- Davies & Whittred. 1980. The Association between Selected Corporate Attributes and Timeliness in Corporate Reporting: Further Analysis. *ABACUS*, pp.48-60.
- Dyer & McHugh. 1975. The Timeliness of The Australian Annual Report. *Journal of Accounting Research*, Autumn, pp.204-219.
- Forum for Corporate Governance in Indonesia (FCGI), 2000, *Corporate governance*.
- Givoli D. & Palmon, D. 1982. Timeliness and Annual Earning announcement, some empirical evidence. *The Accounting Review*, July, pp.486-508.

- Gunarsih, T. & Hartadi, B. 2008. Struktur Corporate Governance dan Ketepatan Waktu Penyampaian Laporan Keuangan: Studi pada Perusahaan Jasa di BEI. *Jurnal Keuangan dan Perbankan*, Vol.12, No. 2, pp.204-216.
- Hsieh, W.K., Liu, S.M., & Hsieh, S.Y. Hybrid Neural Network Bankruptcy Prediction: An Integration of Financial Ratios, Intellectual Capital Ratios, MDA, and Neural Network Learning. *Working Paper*.
- Hu, Y. C. & Tseng, F.M. 2005. Applying Backpropagation Neural Networks to Bankruptcy Prediction. *International Journal of Electronic Business Management*. Vol.3, No.2, pp.97-103.
- Kim, C.N. & Jun, S.G. A Neural Network Approach to Compare Predictive Value of Accounting Versus Market Data. *Working Paper*.
- KNKG.2006. *Pedoman Umum Good Corporate Governance*.
- Kross, W. 1982. Earning and Announcement Time Lags. *Journal of Business Research*, September, pp.267-281.
- Naim, A. 1999. Nilai Informasi Ketepatan Waktu Penyampaian Laporan Keuangan: Analisis Empirik Regulasi Informasi di Indonesia. *Jurnal Ekonomi dan Bisnis*, Vol.14, pp.85-100.
- OECD. 1999. *The OECD Principles of Corporate Governance*, <http://www.oecd.org/daf/governance/principles.html>. Di-download Agustus 2008.
- Perez, M. *Neural Networks Applications in Bankruptcy Forecasting : A State of The Art. Working Paper*.
- Priyastiwi. 2002. Analisis Efek Interaksi antara Tipe Earning dan Ketepatan Waktu Laporan Keuangan terhadap Return Saham. *Kajian Bisnis*, Januari-April, hal.149-161.
- Quah, T.S. & Srinivasan. Improving Returns on Stock Investment Through Neural Network Selection. *Working Paper*.
- Wiwik, E. H. 1996. Faktor-faktor yang Memperngaruhi Keterlambatan Penerbitan Laporan Keuangan Perusahaan Publik di Indonesia. *Tesis*. Tidak Dipublikasikan, Universitas Gadjah Mada Yogyakarta.