

BAB 4 ANALISIS DAN PEMBAHASAN

Bab 4 ini akan membahas hasil penelitian karya akhir dalam mem-*forecast* harga saham yang termasuk dalam indeks LQ45. Penulis akan membandingkan hasil *forecast* menggunakan metode *Artificial Neural Network* (ANN) *Backpropagation* dengan metode *time series forecasting* yang dalam ruang lingkup penelitian ini akan menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA). Tujuan dari perbandingan tersebut adalah menguji apakah metode ANN *Backpropagation* signifikan secara statistik lebih akurat dari metode ARIMA.

4.1 Pembentukan Model *Forecast* Harga Saham

Pada karya akhir ini, *forecast* harga saham dilakukan dengan mencari hubungan antara variabel data *intermarket* seperti harga minyak, harga emas, kurs Rupiah terhadap Dolar Amerika, IHSG (Indeks Harga Saham Gabungan), KLSE (Kuala Lumpur *Stock Exchange*), STI (Strait Times Index), DJI (Dow Jones Index), dan harga masing-masing saham indeks LQ45, terhadap masing-masing harga saham indeks LQ45 keesokan harinya. Dalam mencari hubungan tersebut, akan digunakan dua buah model. Model pertama menggunakan model ARIMA, dan model kedua menggunakan ANN. Kedua model ini kemudian akan dibandingkan untuk mengetahui model manakah yang terbaik dalam mem-*forecast* harga saham-saham indeks LQ45.

4.1.1 Model ARIMA (*Autoregressive Integrated Moving Average*)

Bentuk umum model ARIMA adalah ARIMA (p,d,q) dimana p menunjukkan notasi untuk orde *autoregressive*, d menunjukkan tingkat pembedaan (*differencing*), dan q menunjukkan notasi orde dari *moving average*. Sifat yang perlu diperhatikan dalam pembentukan model ARIMA khususnya dan analisa *time series* umumnya adalah data harus stasioner, dan tidak ada autokorelasi. Dengan mencari model yang memenuhi sifat stasioneritas dan non-autokorelasi, maka akan didapat model ARIMA yang baik.

Penulis menggunakan SPSS versi 17 dalam memodelkan ARIMA. SPSS menyediakan “*Expert Modeler*” yang memberikan kemudahan dalam memperoleh model ARIMA terbaik tanpa harus melihat atau memeriksa nilai-nilai stasioneritas dan autokorelasi secara manual. *Expert Modeler* dapat mencari model ARIMA terbaik secara otomatis untuk suatu data *time series* (Yamin, 2009, p. 34). Menurut Tsay (2005, p. 16) *Expert Modeler* dapat mengestimasi model *univariate* ARIMA, dan model *multivariate* ARIMA untuk data *time series* dan kemudian menghasilkan *forecast* terhadap data *time series* tersebut. Prosedur yang dilakukan oleh *Expert Modeler* secara otomatis mengidentifikasi dan mengestimasi *the best fitting* ARIMA untuk satu atau lebih variabel independen, sehingga tidak memerlukan prosedur percobaan berulang-ulang (*trial and error*).

4.1.1.1 Pemilihan Variabel Dependen dan Independen

Pada tahapan ini, variabel-variabel yang akan dianalisis ditentukan apakah variabel tersebut digolongkan ke dalam variabel dependen atau independen. Dari semua variabel yang digunakan dalam karya akhir ini, harga masing-masing saham LQ45 1 hari ke depan digolongkan ke dalam variabel dependen. Sedangkan harga minyak, harga emas, kurs Rupiah terhadap Dolar Amerika, IHSG (Indeks Harga Saham Gabungan), KLSE (Kuala Lumpur *Stock Exchange*), STI (*Strait Times Index*), DJI (*Dow Jones Index*), dan harga saat ini untuk masing-masing saham indeks LQ45 digolongkan ke dalam variabel independen. Semua data itu kemudian diolah dengan menggunakan SPSS untuk mencari model *multivariate* ARIMA yang *best fit*, menggunakan *Expert Modeler*.

4.1.1.2 Pembuatan Spesifikasi Model

Dalam membuat model ARIMA, tahapan yang dilakukan oleh *Expert Modeler* SPSS adalah:

- a) Melakukan transformasi pada variabel dependen dan independen, misalnya transformasi *natural log*
- b) Menentukan *lag* masing-masing variabel
- c) Menentukan *differencing* masing-masing variabel

Ketiga tahapan di atas dilakukan secara otomatis untuk mencari orde model AR, MA, dan *differencing* yang menghasilkan nilai probabilita < 0.05 . Jika masing-

masing variabel telah signifikan secara statistik, maka akan didapat model ARIMA yang dianggap dapat memodelkan data *time series*.

Tabel 4.1 menunjukkan hasil pembentukan model ARIMA saham BBRI. Estimasi model AR(1) dan MA(2) signifikan karena nilainya signifikansinya < 0.05 . Terdapat *differencing* orde 1 untuk menghilangkan ketidakstasioneran data. Terlihat bahwa variabel independen yang berpengaruh terhadap variabel dependen BBRI adalah harga emas, IHSG, dan STI, yang kesemuanya mempunyai lag, dan signifikan karena nilai probabilita < 0.05 .

Tabel 4.1 Parameter statistik model ARIMA saham BBRI

ARIMA Model Parameters								
				Estimate	SE	t	Sig.	
BBRI-Model_1	BBRI	Natural Log	Constant		.001	.000	2.391	.017
			AR	Lag 1	.896	.022	41.015	.000
			Difference		1			
		MA	Lag 1	.845	.033	25.944	.000	
			Lag 2	.122	.027	4.520	.000	
		Gold_Price	Natural Log	Delay		1		
	Numerator			Lag 0	-.146	.053	-2.723	.007
	Difference				1			
	IHSG	Natural Log	Numerator	Lag 0	.190	.040	4.725	.000
				Lag 1	-.412	.044	-9.277	.000
			Difference		1			
			Denominator	Lag 2	.440	.060	7.310	.000
	STI	Natural Log	Numerator	Lag 0	-.125	.052	-2.404	.016
				Lag 2	.211	.052	4.085	.000
Denominator			Lag 2	-.672	.183	-3.682	.000	
Delay				2				
Difference				1				

Dari Tabel 4.1, dapat disimpulkan bahwa model ARIMA yang sesuai adalah ARIMA (1,1,2), yang juga dapat dilihat dari hasil keluaran SPSS seperti pada Tabel 4.2 di bawah ini.

Tabel 4.2 Model ARIMA saham BBRI

Model Description			
			Model Type
Model ID	BBRIplus1	Model_1	ARIMA(1,1,2)

Tabel 4.2 menunjukkan bahwa data BBRI awalnya tidak stasioner, tetapi setelah dilakukan *differencing* orde 1 ($d = 1$) maka datanya sekarang sudah stasioner. Terdapat proses *autoregressive* dengan orde 1 serta proses *moving average* dengan orde 2 di model ARIMA tersebut.

Tahapan berikutnya adalah menguji kecocokan model ARIMA yang telah didapatkan. Kecocokan model ini dapat diperiksa dari nilai statistik Ljung-Box Q, dimana hipotesisnya adalah:

- Ho: Model ARIMA layak untuk digunakan
- H1: Model ARIMA tidak layak digunakan

Kriteria uji: tolak Ho jika nilai signifikansi statistik LjungBox Q < 0.05.

Tabel 4.3 Statistik Model ARIMA saham BBRI

Model Statistics											
Model	Number of Predictors	Model Fit statistics						Ljung-Box Q(18)			Number of Outliers
		R-squared	RMSE	MAPE	MAE	MaxAPE	MaxAE	Statistics	DF	Sig.	
BBRIplus1-Model_1	3	.996	127.649	2.147	88.484	12.833	596.025	16.904	15	.325	0

Dalam Tabel 4.3 di atas, diketahui nilai probabilita signifikansi sebesar 0.325 (<0.05), maka hipotesis nol diterima yang berarti bahwa model ARIMA (1,1,2) adalah model yang layak digunakan untuk *forecast* saham BBRI. Untuk hasil pembuatan model ARIMA saham LQ45 lainnya, dapat dilihat pada Tabel 4.4 berikut ini, sedangkan detail proses estimasinya dapat dilihat pada Lampiran B.

Tabel 4.4 Model ARIMA saham LQ45

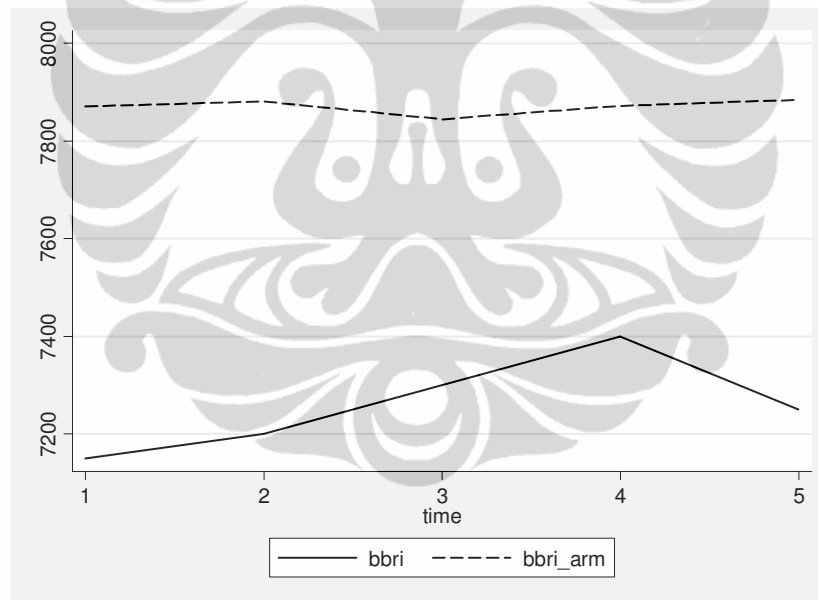
No	Saham LQ45	ARIMA Model
1.	AALI	ARIMA(0,1,0)
2.	ADRO	ARIMA(0,1,17)
3.	ANTM	ARIMA(0,1,0)
4.	ASII	ARIMA(0,1,17)
5.	BBCA	ARIMA(0,1,13)
6.	BBNI	ARIMA(0,1,0)
7.	BBRI	ARIMA(1,1,2)
8.	BDMN	ARIMA(0,1,0)
9.	BISI	ARIMA(1,1,0)
10.	BLTA	ARIMA(0,1,10)
11.	BMRI	ARIMA(0,1,17)
12.	BNBR	ARIMA(0,1,15)
13.	BRPT	ARIMA(1,1,1)
14.	BTEL	ARIMA(2,1,1)
15.	BUMI	ARIMA(0,1,18)
16.	DEWA	ARIMA(0,1,1)
17.	ELSA	ARIMA(0,1,0)
18.	ELTY	ARIMA(0,1,0)
19.	ENRG	ARIMA(1,1,15)
20.	GGRM	ARIMA(0,1,2)
21.	HEXA	ARIMA(0,1,9)
22.	INCO	ARIMA(0,1,0)
23.	INDF	ARIMA(1,1,0)
24.	INDY	ARIMA(0,1,2)
25.	INKP	ARIMA(0,1,5)
26.	INTP	ARIMA(0,1,0)
27.	ISAT	ARIMA(0,1,0)
28.	ITMG	ARIMA(0,1,0)
29.	JSMR	ARIMA(0,1,0)
30.	KLBF	ARIMA(0,1,0)
31.	LPKR	ARIMA(3,1,0)
32.	LSIP	ARIMA(0,1,7)
33.	MEDC	ARIMA(0,1,0)
34.	MIRA	ARIMA(0,1,0)
35.	PGAS	ARIMA(0,1,0)
36.	PTBA	ARIMA(0,1,0)
37.	SGRO	ARIMA(0,1,0)
38.	SMCB	ARIMA(0,1,0)
39.	SMGR	ARIMA(0,1,0)
40.	TINS	ARIMA(0,1,0)
41.	TLKM	ARIMA(0,1,0)
42.	TRUB	ARIMA(0,1,10)
43.	UNSP	ARIMA(1,1,11)

Tabel 4.4 (lanjutan)

No	Saham LQ45	ARIMA Model
44.	UNTR	ARIMA(0,1,1)
45.	UNVR	ARIMA(0,1,0)

4.1.1.3 Melakukan *Forecast* Dengan Model ARIMA

Setelah didapatkan model ARIMA, tahapan selanjutnya adalah melakukan *forecast* untuk masing-masing harga saham LQ45 dengan tujuan memperkirakan harga saham 5 hari ke depan (1 minggu). Hasil dari *forecast* tersebut akan dibandingkan dengan harga saham sebenarnya. Pada Gambar 4.1 terlihat perbandingan antara harga saham aktual BBRI yang dilambangkan dengan garis lurus, sedangkan harga saham hasil *forecast* ARIMA untuk 5 hari ke depan dilambangkan dengan garis putus-putus.



Gambar 4.1 Contoh *Forecast* ARIMA Data 5 Hari Saham BRI

Untuk perbandingan hasil *forecast* model ARIMA dibandingkan dengan harga saham aktual untuk saham-saham LQ45 yang lain, dapat dilihat pada Lampiran D.

4.1.2 Model ANN (*Artificial Neural Network*)

Proses membangun arsitektur model ANN adalah menentukan parameter-parameternya. Seperti yang telah disebutkan pada Bab 2, bahwa arsitektur ANN terdiri dari 3 jenis *layer*. *Layer* yang terdepan adalah *layer* input (*input layer*). *Layer* yang paling belakang adalah *layer* output (*output layer*). Sedangkan *layer* diantara *layer* terdepan dan *layer* paling belakang adalah *layer* tersembunyi (*hidden layer*). Konsep model dalam ANN mirip dengan permodelan regresi, dimana input dalam ANN adalah variabel independen dalam model regresi, sedangkan output dalam ANN adalah variabel dependen dalam model regresi. Koefisien variabel independen dalam model regresi adalah bobot masing-masing *neuron* dalam *layer*. Bedanya adalah, model ANN dalam menentukan model terbaik, dilakukan dengan pembelajaran (*training*).

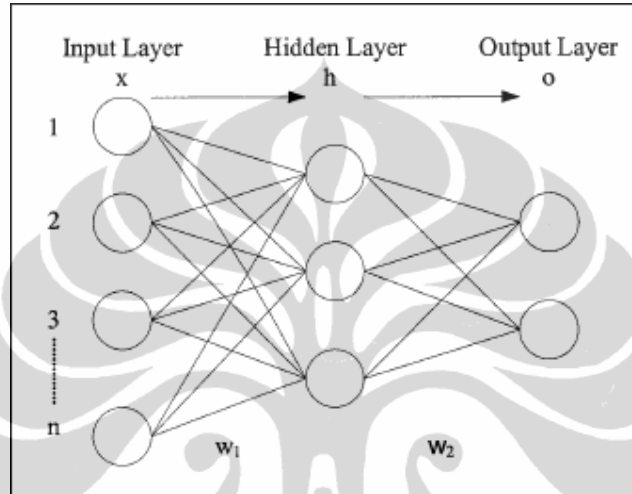
Parameter pertama yang harus ditentukan dalam permodelan ANN adalah jumlah *hidden layer*. Parameter berikutnya adalah jumlah *neuron* di masing-masing *layer*, fungsi transfer (*transfer function*) di masing-masing *layer*, dan algoritma pelatihan (*training*) model ANN.

Jumlah *neuron* di *input layer* harus sesuai dengan jumlah *inputnya*. Dalam hal *forecast* harga saham, *input* adalah data harga minyak, harga emas, kurs Rupiah terhadap Dolar Amerika, IHSG (Indeks Harga Saham Gabungan), KLSE (Kuala Lumpur *Stock Exchange*), STI (Strait Times Index), DJI (Dow Jones Index), dan harga masing-masing saham indeks LQ45. Jumlah *neuron* di *output layer* harus satu, yakni harga saham yang akan kita *forecast* satu hari ke depan. Jumlah *neuron hidden layer*, jumlah *hidden layer*, jenis fungsi aktivasi per *layer*, dan jenis *training* akan didapatkan melalui serangkaian percobaan.

Pemodelan *forecast* harga saham dengan metode ANN menggunakan analisa hasil observasi berbagai macam percobaan untuk mendapatkan model ANN terbaik yang dapat merepresentasikan dengan akurat pergerakan suatu saham tertentu. Model dianggap akurat jika kombinasi jumlah *hidden layer*, jumlah *neuron* pada *hidden layer*, jenis fungsi aktivasi per *layer* dan jenis *training* memberikan RMSE (*Root Mean Square Error*) terkecil antara harga saham *forecast* model ANN dengan harga saham sebenarnya. Kombinasi parameter-parameter ini disebut arsitektur ANN.

4.1.2.1 Percobaan Pembentukan Arsitektur ANN

Secara umum, arsitektur ANN dapat dilihat pada Gambar 4.5 berikut. Tampak bahwa arsitektur ANN terdiri dari *input layer*, *hidden layer*, dan *output layer*. Tiap *layer* memiliki *neuron-neuron* yang di Gambar 4.2 direpresentasikan dengan lingkaran.



Gambar 4.2: Arsitektur ANN secara umum



Sumber: Iskandar (2005)

Seperti yang telah dijelaskan sebelumnya, dalam mencari kombinasi tepat untuk arsitektur ANN, penulis menganalisa setiap kombinasi parameter yang menghasilkan RMSE terkecil antara harga saham hasil *forecast* dengan harga saham sebenarnya. Alat bantu yang digunakan adalah program Matlab versi 7.7, yang di dalamnya sudah terdapat *Neural Network Toolbox* yang membantu dalam melakukan pemrograman percobaan ini. Faktor penentu kombinasi tersebut dapat dilihat pada Tabel 4.5 berikut.


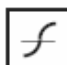


Tabel 4.5 Kombinasi parameter ANN

Parameter	Kombinasi	Keterangan
Jumlah <i>hidden layer</i>	1 <i>hidden layer</i> 2 <i>hidden layer</i>	-
Jenis <i>training</i>	Traingd	<i>Gradient descent backpropagation</i>

Tabel 4.5 (lanjutan)

Parameter	Kombinasi	Keterangan
	Traindm	<i>Gradient descent backpropagation with momentum</i>
	Traincgb	<i>Conjugate gradient backpropagation with Powell-Beale restarts</i>
	Trainscg	<i>Scaled conjugate gradient backpropagation</i>
	Trainbfg	<i>BFGS quasi-Newton backpropagation</i>
	Trainlm	<i>Levenberg-Marquardt backpropagation</i>
	Trainb	<i>Batch training with weight and bias learning rules</i>
	Trainbr	<i>Bayesian regulation backpropagation</i>
	Trainгда	<i>Gradient descent with adaptive learning rate backpropagation</i>
	Trainгдаx	<i>Gradient descent with momentum and adaptive learning rate backpropagation</i>
	Trainoss	<i>One-step secant backpropagation</i>
	Trainrp	<i>Resilient backpropagation</i>
	Trains	<i>Sequential order incremental training with learning functions</i>
Fungsi aktivasi di output layer	Tansig 	<i>Hyperbolic tangent sigmoid transfer function</i>
	logsig 	<i>Log-sigmoid transferfunction</i>

Tabel 4.5 (lanjutan)

Parameter	Kombinasi	Keterangan
	purelin 	<i>Linear transfer function</i>
Fungsi aktivasi di <i>hidden layer</i>	tansig 	<i>Hyperbolic tangent sigmoid transfer function</i>
	logsig 	<i>Log-sigmoid transfer function</i>
	purelin 	<i>Linear transfer function</i>
Jumlah neuron per <i>hidden layer</i>	1 s/d 30 <i>neuron</i>	Jumlah neuron di <i>hidden layer</i> 1 dan <i>hidden layer</i> 2 adalah sama

Ringkasan dari hasil percobaan dengan menggunakan 1 *hidden layer* dapat dilihat pada Tabel 4.6, sedangkan ringkasan dari hasil percobaan dengan menggunakan 2 *hidden layer* dapat dilihat pada Tabel 4.7. Ringkasan tersebut menampilkan 20 buah percobaan yang menghasilkan RMSE terkecil untuk 1 *hidden layer* dan 2 *hidden layer*.

**Tabel 4.6 Hasil percobaan arsitektur ANN dengan RMSE terkecil
(menggunakan 1 *hidden layer*)**

No. Obs	Jenis Training	Fungsi Aktivasi di Output layer	Fungsi Aktivasi di Hidden layer	Jumlah Neuron per Hidden layer	RMSE (Root Mean Square Error)
948	traincgp	purelin	tansig	26	1,4567%
961	traincgp	purelin	logsig	11	1,4577%
1897	trainlm	logsig	logsig	23	1,4584%
3377	trainrp	logsig	tansig	19	1,4603%
1196	traincgb	purelin	tansig	22	1,4612%
880	traincgp	logsig	logsig	14	1,4657%
1957	trainlm	purelin	tansig	27	1,4696%
1819	trainlm	tansig	logsig	29	1,4705%
1351	trainscg	logsig	tansig	9	1,4717%
1975	trainlm	purelin	logsig	17	1,4779%
1283	trainscg	tansig	tansig	25	1,4788%
1861	trainlm	logsig	tansig	15	1,4794%
1779	trainlm	tansig	tansig	17	1,4808%
3303	trainrp	tansig	tansig	29	1,4834%
1796	trainlm	tansig	logsig	6	1,4851%
2276	trainbr	tansig	tansig	10	1,4860%
2319	trainbr	tansig	logsig	25	1,4867%
2316	trainbr	tansig	logsig	22	1,4868%
1816	trainlm	tansig	logsig	26	1,4881%
2458	trainbr	purelin	tansig	24	1,4882%

**Tabel 4.7 Hasil percobaan arsitektur ANN dengan RMSE terkecil
(menggunakan 2 *hidden layer*)**

No. Obs	Jenis Training	Fungsi Aktivasi di Output layer	Fungsi Aktivasi di Hidden layer	Jumlah Neuron per Hidden layer	RMSE (Root Mean Square Error)
2277	trainbr	tansig	tansig	11	1,4198%
527	traincgf	tansig	tansig	25	1,4201%
536	traincgf	tansig	logsig	6	1,4253%
1790	trainlm	tansig	tansig	28	1,4277%
1812	trainlm	tansig	logsig	22	1,4312%
1708	trainbfg	purelin	tansig	30	1,4325%
2270	trainbr	tansig	tansig	4	1,4472%
1041	traincgb	tansig	logsig	7	1,4545%
1892	trainlm	logsig	logsig	18	1,4618%

Tabel 4.7 (lanjutan)

No. Obs	Jenis Training	Fungsi Aktivasi di Output layer	Fungsi Aktivasi di Hidden layer	Jumlah Neuron per Hidden layer	RMSE (Root Mean Squared Error)
1958	trainlm	purelin	tansig	28	1,4659%
1567	trainbfg	tansig	logsig	29	1,4667%
1713	trainbfg	purelin	logsig	7	1,4679%
1869	trainlm	logsig	tansig	23	1,4736%
1389	trainscg	logsig	logsig	19	1,4752%
1792	trainlm	tansig	tansig	30	1,4771%
853	traincgp	logsig	tansig	15	1,4771%
704	traincgf	purelin	logsig	6	1,4793%
1888	trainlm	logsig	logsig	14	1,4801%
2279	trainbr	tansig	tansig	13	1,4861%
1955	trainlm	purelin	tansig	25	1,4867%

Dalam percobaan pembentukan model ANN, penulis membuat program yang mencari model ANN terbaik. Program dibuat dengan pemrograman Matlab. Kode program Matlab yang digunakan untuk mencari arsitektur ANN terbaik dapat dilihat pada Lampiran C.


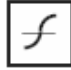
4.1.2.2 Hasil Percobaan Pembentukan Arsitektur ANN

Berdasarkan hasil percobaan di atas, RMSE terkecil didapat pada nomor observasi 2277 pada Tabel 4.4 yang menggunakan 2 *hidden layer*. Hasil percobaan tersebut menunjukkan bahwa model ANN terbaik adalah menggunakan metode *training Bayesian regulation backpropagation*, fungsi aktivasi pada *hidden layer* dan *output layer* menggunakan *Hyperbolic tangent sigmoid transfer function*, dan jumlah *neuron* pada *hidden layer* sebanyak 11 buah. Tabel 4.8 merupakan ringkasan dari parameter-parameter arsitektur ANN terbaik.

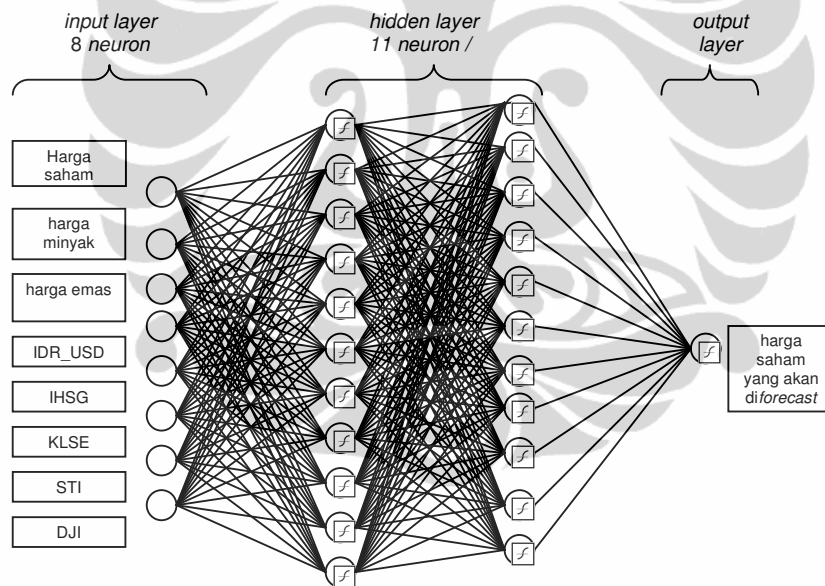
Tabel 4.8 Arsitektur ANN terbaik untuk *forecast* saham LQ45

Parameter	Hasil	Keterangan
Jumlah <i>Hidden layer</i>	2 <i>hidden layer</i>	-
Jenis <i>Training</i>	trainbr	<i>Bayesian regulation backpropagation</i>

Tabel 4.8 (lanjutan)

Parameter	Hasil	Keterangan
Fungsi Aktivasi di Output Layer	tansig 	<i>Hyperbolic tangent sigmoid transfer function</i>
Fungsi Aktivasi di Hidden layer	tansig 	<i>Hyperbolic tangent sigmoid transfer function</i>
Jumlah Neuron Per Hidden layer	11	-

Dari parameter arsitektur ANN pada Tabel 4.8, dapat dibangun gambar arsitektur ANN seperti pada Gambar 4.3 berikut.


Gambar 4.3 Arsitektur ANN Terbaik untuk *forecast* saham LQ45

4.1.3 Melakukan *Forecast* Dengan Model ANN

Setelah didapat arsitektur ANN yang terbaik, tahapan berikutnya melakukan *training* pada model ANN untuk setiap harga saham LQ45, agar model dapat mempelajari karakteristik pergerakan masing-masing harga saham LQ45. *Training* berguna untuk mencari bobot masing-masing *neuron*. Masing-masing

harga saham LQ45 dimodelkan dengan satu model ANN, dengan arsitektur ANN yang sama, hanya berbeda bobot pada masing-masing *neuron*.

Tahapan selanjutnya adalah menjalankan model ANN dengan variabel-variabel input, untuk kemudian digunakan untuk mem*forecast* harga saham 1 hari sampai dengan 5 hari ke depan. Hal ini dilakukan untuk seluruh saham LQ45 (45 buah saham). Contoh *forecast* harga saham BBRI 5 hari ke depan dengan ANN dapat dilihat pada Gambar 4.4 berikut. Harga saham aktual BBRI dilambangkan dengan garis lurus, sedangkan harga saham hasil *forecast* dengan model ANN dilambangkan dengan garis putus-putus.



Gambar 4.4: Perbandingan hasil *forecast* saham BBRI menggunakan ANN dengan data harga saham sebenarnya

Untuk hasil *forecast* ANN terhadap saham-saham LQ45 yang lain, dapat dilihat pada Lampiran D.

4.2 Perbandingan Kinerja Kedua Metode *Forecast*

Pembahasan di atas telah menjelaskan mengenai pembentukan model dan *forecast* menggunakan ARIMA dan ANN. Sub bab ini akan membandingkan keakuratan *forecast* harga saham dengan menggunakan ARIMA dibandingkan dengan menggunakan ANN. Keakuratan *forecast* diukur dengan membandingkan *error* yang terjadi antara harga hasil keluaran kedua model (harga *forecast*)

dengan harga sebenarnya. Terdapat 3 metode pengukuran *error* yang akan digunakan, yakni RMSE (*Root Mean Squared Error*), MAE (*Mean Absolute Error*), dan MAPE (*Mean Absolute Percentage Error*). Untuk meningkatkan keyakinan dalam memutuskan metode manakah yang paling tepat dalam *forecast* harga saham, sub bab 4.3 akan menjelaskan tentang uji hipotesis perbandingan keakuratan kedua metode ini.

Terdapat 3 model pengukuran keakuratan hasil *forecast*, yaitu RMSE, MAE, dan MAPE. RMSE merupakan akar kuadrat rata-rata dari selisih antara output model dengan data yang sebenarnya. Rumus MSE adalah sebagai berikut (Buwana, 2006, p. 49):

$$RMSE = \sqrt{\frac{\sum (n_f - n_a)^2}{m}} \quad (4.1)$$

MAE merupakan hasil nilai absolut dari selisih antara nilai keluaran model dengan data sebenarnya. Rumus MAE adalah sebagai berikut (Buwana, 2006, p. 49):

$$MAE = \frac{\sum |n_f - n_a|}{m} \quad (4.2)$$

Sedangkan MAPE adalah perhitungan MAE yang hasilnya dalam bentuk persentase, seperti rumus berikut (Buwana, 2006, p. 49):

$$MAPE = \frac{1}{m} * \frac{\sum |n_f - n_a|}{n_a} * 100\% \quad (4.3)$$

Penjelasan rumus tersebut di atas adalah sebagai berikut:

n_f = harga saham *forecast*

n_a = harga saham *aktual*

m = jumlah data (dalam hal ini adalah 5, karena *forecast* 5 hari ke depan).

Tabel 4.9 Perbandingan RMSE, MAE, MAPE untuk metode ANN dan ARIMA

No	Saham LQ45	ANN			ARIMA		
		RMSE	MAE	MAPE	RMSE	MAE	MAPE
1	AALI (Astra Agro Lestari)	132,832	69.413	0,291%	596,830	340,65	1,432%
2	ADRO (Adaro Energi)	30,944	15,158	0,885%	380,555	181,28	10,635%
3	ANTM (Aneka Tambang)	0,795	0,341	0,016%	114,018	40,00	1,862%
4	ASII (Astra International)	989,011	290,362	0,793%	928,758	325,25	0,892%

Tabel 4.9 (lanjutan)

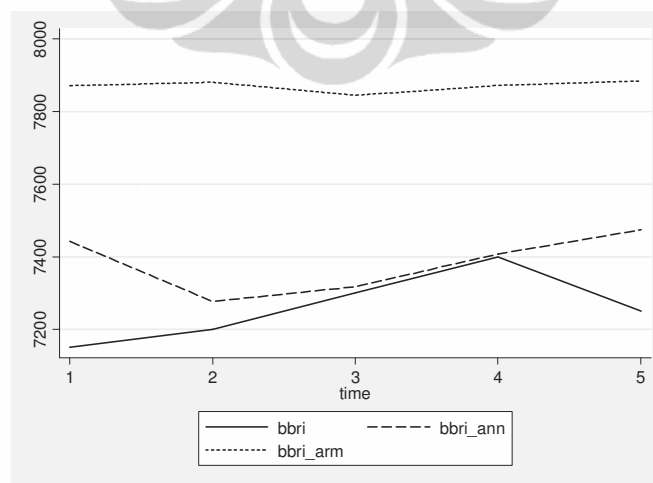
No	Saham LQ45	ANN			ARIMA		
		RMSE	MAE	MAPE	RMSE	MAE	MAPE
5	BBCA (Bank Central Asia)	126,091	68,249	1,397%	93,894	50,42	1,031%
6	BBNI (Bank Negara Indonesia)	45,719	22,729	1,210%	73,126	38,93	2,071%
7	BBRI (Bank Rakyat Indonesia)	318,762	123,609	1,717%	1,259,209	611,03	8,432%
8	BDMN (Bank Danamon Indonesia)	242,851	83,543	1,625%	264,125	118,85	2,317%
9	BISI (Bisi International)	36,618	16,262	1,153%	54,311	17,22	1,211%
10	BLTA (Berlian Laju Tanker)	42,141	15,781	2,562%	32,141	12,87	2,086%
11	BMRI (Bank Mandiri)	88,592	38,680	0,865%	158,523	80,88	1,809%
12	BNBR (Bakrie & Brothers)	66,308	32,380	42,288%	6,259	3,03	3,959%
13	BRPT (Barito Pacific)	31,236	13,263	1,071%	25,997	12,98	1,041%
14	BTEL (Bakrie Telecom)	5,669	2,189	1,548%	5,202	1,85	1,314%
15	BUMI (Bumi Resources)	227,666	80,674	3,477%	131,939	55,02	2,407%
16	DEWA (Darma Henwa)	19,353	9,325	8,678%	3,729	1,44	1,343%
17	ELSA (Elnusa)	72,037	34,895	11,039%	13,511	6,02	1,912%
18	ELTY (Bakrieland Development)	10,320	4,941	2,189%	15,521	5,82	2,516%
19	ENRG (Energi Mega Persada)	11,744	5,106	3,236%	4,844	2,37	1,505%
20	GGRM (Gudang Garam)	1.798,401	838,971	3,070%	3,290,910	1.565,77	5,704%
21	HEXA (Hexindo Adiperkasa)	162,310	80,070	2,124%	187,693	84,92	2,263%
22	INCO (International Nickel Indonesia)	35,838	14,341	0,382%	99,214	51,38	1,373%
23	INDF (Indofood Sukses Makmur)	76,325	29,051	0,758%	139,630	62,64	1,651%
24	INDY (Indika Energi)	71,817	34,366	1,546%	152,533	62,53	2,830%
25	INKP (Indah Kiat Pulp & Paper)	12,048	5,430	0,266%	86,587	30,90	1,516%
26	INTP (Indocement Tunggul Perkasa)	188,872	69,189	0,508%	315,574	132,54	0,983%
27	ISAT (Indosat)	77,245	37,887	0,720%	254,338	92,72	1,802%
28	ITMG (Indo Tambangraya Megah)	399,060	147,384	0,462%	1.241,334	555,15	1,745%
29	JSMR (Jasa Marga)	15,518	5,745	0,326%	17,133	7,37	0,417%
30	KLBF (Kalbe Farma)	96,012	45,363	2,867%	29,473	12,02	0,762%
31	LPKR (Lippo Karawaci)	3,933	1,682	0,332%	18,454	7,27	1,438%
32	LSIP (London Sumatera)	41,265	17,448	0,194%	621,770	341,34	3,823%
33	MEDC (Medco Energi International)	37,009	15,440	0,620%	40,059	14,61	0,586%
34	MIRA (Mira International Resources)	42,836	21,267	8,704%	14,943	7,03	2,899%
35	PGAS (Perusahaan Gas Negara)	38,298	14,698	0,396%	155,574	45,42	1,237%
36	PTBA (Tambang Batubara Bukit Asam)	250,398	124,824	0,794%	1,237,983	592,36	3,769%
37	SGRO (Sampoerna Agro)	45,960	24,331	0,909%	182,329	87,24	3,287%
38	SMCB (Holchim Indonesia)	70,225	35,429	1,964%	39,920	16,35	0,911%
39	SMGR (Semen Gresik)	66,046	32,655	0,432%	91,327	50,37	0,669%

Tabel 4.9 (lanjutan)

No	Saham LQ45	ANN			ARIMA		
		RMSE	MAE	MAPE	RMSE	MAE	MAPE
40	TINS (Timah)	34,145	11,429	0,533%	84,985	33,44	1,569%
41	TLKM (Telekomunikasi Indonesia)	65,088	30,264	0,364%	343,433	112,36	1,366%
42	TRUB (Truba Alam Manunggal Engineering)	16,636	7,839	6,862%	7,178	3,47	3,055%
43	UNTR (United Tractors)	346,189	151,710	0,887%	269,035	141,80	0,834%
44	UNVR (Unilever Indonesia),	140,672	43,330	1,706%	295,707	133,96	5,048%
45	UNSP (Bakrie Sumatra Plantations)	40,723	19,889	3,899%	23,899	10,43	2,059%

Sumber: data hasil olahan karya akhir ini

Untuk contoh saham BBRI (nomor 7 pada Tabel 4.9), model ANN mempunyai RMSE 318.762, sedangkan model ARIMA mempunyai RMSE 1259.209. Model ANN mempunyai MAE 123.609, sedangkan model ARIMA mempunyai MAE 611.03. Model ANN mempunyai MAPE 1.717%, sedangkan ARIMA mempunyai MAPE 8.432%. Dari ketiga model pengukuran keakuratan, dapat disimpulkan bahwa model ANN lebih akurat dalam *forecast* harga saham BBRI karena memiliki RMSE, MAE, dan MAPE terkecil. Secara grafik, pada Gambar 4.5, model ANN (garis putus-putus) memang lebih akurat daripada model ARIMA (garis titik-titik), karena grafik harga saham BBRI hasil *forecast* model ANN lebih mendekati grafik harga saham BBRI yang sebenarnya.



Gambar 4.5 Perbandingan hasil *forecast* saham BBRI antara model ANN dengan ARIMA

Berdasarkan percobaan keseluruhan saham LQ45, secara rata-rata model ANN mempunyai RMSE sebesar 148,257. Artinya adalah, menurut rasio RMSE harga saham hasil *forecast* model ANN berbeda sebesar $\pm 148,257$ Rupiah dari harga saham sebenarnya. Menurut rasio MAE, model ANN menghasilkan *forecast* harga saham yang berbeda sebesar $\pm 61,932$ Rupiah dari harga saham yang sebenarnya. Terakhir, menurut rasio MAPE, harga saham hasil *forecast* model ANN berbeda $\pm 2,84\%$ dari harga saham sebenarnya. Untuk hasil perbandingan *forecast* metode ANN dengan ARIMA terhadap saham-saham LQ45 yang lain, dapat dilihat pada Lampiran D.

4.3 Uji Hipotesis Keakuratan Model

Sub bab 4.2 telah membahas perbandingan kinerja kedua model (ANN dan ARIMA) dalam mem*forecast* harga saham. Keakuratan masing-masing model tergambar pada Tabel 4.9. Akan tetapi, tingkat keakuratan tersebut belum diketahui apakah signifikan secara statistik atau tidak. Untuk mengetahuinya, maka pada sub bab 4.3 ini akan membahas mengenai uji hipotesis kinerja *forecast* kedua model untuk masing-masing saham LQ45.

Uji hipotesis yang dilakukan adalah Uji Diebold-Mariano. Uji ini berguna untuk mengetahui signifikansi keakuratan *forecast* untuk data *out of sample*. Dalam karya akhir ini, *forecast* yang dilakukan adalah 5 hari ke depan, berarti ini adalah data *out of sample* dari sampel data historisnya.

Teori yang melandasi metode uji Diebold-Mariano telah dibahas pada Bab II Landasan Teori. Pada sub bab ini akan dipraktekkan implementasinya. Uji ini menggunakan pembandingan MSE (*Mean Squared Error*), dan apabila salah satu metode (ANN atau ARIMA) mempunyai MSE lebih kecil (lebih akurat), maka kemudian metode tersebut akan diuji signifikansi keakuratannya. Kriteria uji Diebold-Mariano adalah menggunakan hipotesis:

- Ho: Keakuratan *forecast* tidak signifikan
- H1: Keakuratan *forecast* signifikan

Kriteria uji: tolak Ho jika nilai signifikansi statistik *p-value* < 0.05 .

Penulis menggunakan perangkat lunak Stata versi 10 dalam melakukan uji Diebold-Mariano, karena fungsi uji Diebold Mariano sudah terdapat di dalamnya.

Contoh hasil pengujian Diebold-Mariano menggunakan program Stata untuk saham BBRI dapat dilihat pada Tabel 4.10.

Tabel 4.10 Hasil uji Diebold Mariano untuk saham BBRI

Saham	Hasil Diebold Mariano Test (<i>forecast accuracy</i>)
BBRI	<pre>. dmariano bbri bbri_ann bbri_arm, crit(MSE) kernel(bartlett) Diebold-Mariano forecast comparison test for actual : bbri Competing forecasts: bbri_ann versus bbri_arm Criterion: MSE over 5 observations Maxlag = 5 chosen by Schwert criterion Kernel : bartlett Series MSE ----- bbri_ann 28382 bbri_arm 381614 Difference -353232 By this criterion, bbri_ann is the better forecast H0: difference is not significant S(1) = -12.62 p-value = 0.0000</pre>

Pada Tabel 4.10, output uji Diebold-Mariano menggunakan perangkat lunak Stata menampilkan p-value 0.0000 dimana nilai ini < 0.05 . Ini berarti bahwa kita menolak H_0 yang menyatakan bahwa keakuratan *forecast* tidak signifikan, sehingga dapat disimpulkan bahwa metode ANN lebih akurat secara signifikan dibandingkan dengan metode ARIMA untuk saham BBRI. Untuk detail hasil uji saham-saham LQ45 lainnya dapat dilihat di Lampiran E.

Setelah melakukan uji Diebold-Mariano pada seluruh saham indeks LQ 45, dapat dibuat ringkasan pengujian seperti yang terdapat pada Tabel 4.11.

Tabel 4.11 Keakuratan *Forecast* Dengan Uji Diebold-Mariano

No	Saham	Keakuratan <i>Forecast</i> Hasil Uji Diebold Mariano	
		ANN Lebih Akurat	ARIMA Lebih Akurat
1.	AALI	X	
2.	ADRO	X	
3.	ANTM	X	
4.	ASII		X
5.	BBCA		X

Tabel 4.11 (lanjutan)

No	Saham	Keakuratan <i>Forecast</i> Hasil Uji Diebold Mariano	
		ANN Lebih Akurat	ARIMA Lebih Akurat
6.	BBNI	X	
7.	BBRI	X	
8.	BDMN	X	
9.	BISI	X	
10.	BLTA		X
11.	BMRI	X	
12.	BNBR		X
13.	BRPT	X	
14.	BTEL		X
15.	BUMI		X
16.	DEWA		X
17.	ELSA		X
18.	ELTY	X	
19.	ENRG		X
20.	GGRM	X	
21.	HEXA	X	
22.	INCO	X	
23.	INDF	X	
24.	INDY	X	
25.	INKP	X	
26.	INTP	X	
27.	ISAT	X	
28.	ITMG	X	
29.	JSMR	X	
30.	KLBF		X
31.	LPKR	X	
32.	LSIP	X	
33.	MEDC	X	
34.	MIRA		X
35.	PGAS	X	
36.	PTBA	X	
37.	SGRO	X	
38.	SMCB		X
39.	SMGR	X	
40.	TINS	X	
41.	TLKM	X	
42.	TRUB		X
43.	UNSP		
44.	UNTR	X	
45.	UNVR	X	

Secara umum, metode ANN lebih akurat dan signifikan secara statistik dibandingkan dengan metode ARIMA. Ini terbukti dari 45 saham LQ45, metode ANN dapat signifikan secara statistik lebih akurat di permodelan 31 saham, dibandingkan dengan metode ARIMA yang hanya akurat memodelkan 14 saham.

4.4 Uji Hipotesis Penelitian

Penelitian ini bertujuan untuk melihat apakah metode ANN dapat memforecast lebih akurat harga saham LQ45 dibandingkan dengan metode ARIMA. Hipotesisnya adalah sebagai berikut:

- Hipotesis nol (H_0): ketepatan *forecast* model ANN *Backpropagation* adalah sama atau tidak akurat (tidak signifikan secara statistik) dalam memforecast perubahan harga saham LQ45 dibandingkan dengan metode *time series forecasting* (ARIMA).
- Hipotesis alternatif (H_a): model ANN *Backpropagation* dapat lebih akurat dan signifikan secara statistik dalam memforecast perubahan harga saham LQ45 dibandingkan dengan metode *time series forecasting* (ARIMA)

Kriteria uji: tolak H_0 jika hasil *forecast* memenuhi kedua kriteria sebagai berikut:

- Hasil uji Diebold-Mariano menunjukkan bahwa model ANN signifikan secara statistik lebih akurat daripada model ARIMA untuk saham-saham LQ45, dan
- Persentase saham-saham LQ45 yang akurat diforecast oleh model ANN lebih besar daripada persentase saham-saham LQ45 yang akurat diforecast oleh model ARIMA.

Dari hasil penelitian, didapat bahwa dari 45 saham LQ45, metode ANN dapat signifikan secara statistik lebih akurat di permodelan 31 saham (69%), dibandingkan dengan metode ARIMA yang hanya akurat memodelkan 14 saham (31%). Ini berarti, kita dapat menolak H_0 , dan menyimpulkan bahwa model ANN lebih akurat dari model ARIMA dalam memforecast harga saham LQ45.

Model ANN terbukti dapat lebih akurat dibandingkan dengan model *multivariate* ARIMA. Hal ini dikarenakan model ANN dapat lebih tepat memodelkan pergerakan saham yang *volatile* dibandingkan model *multivariate*

ARIMA, seperti yang terdapat pada pasar saham negara-negara Asia dan Amerika Latin, termasuk pula Indonesia (McNelis, 2005, p. 18).

Meskipun model ANN lebih akurat dalam memodelkan pergerakan saham, ada beberapa kekurangan ANN disamping kelebihan yang dimiliki, seperti yang dijabarkan oleh Hagen (2006). Kelebihan ANN adalah:

- a) Dapat digunakan untuk himpunan data sampel yang besar (50 *predictors*, dan 15.000 observasi) dengan distribusi yang tidak diketahui.
- b) Kebal (resisten) terhadap kehadiran *outliers* pada data sampel.
- c) Dapat mengenali hampir semua pola data.

Disamping itu, ANN mempunyai beberapa kekurangan, diantaranya (Hagen, 2006):

- a) Model ANN sulit untuk diimplementasikan karena memerlukan pemrograman model yang kompleks.
- b) Hasil dari model ANN sulit diinterpretasikan karena bersifat *black box*.
- c) Memerlukan sampel data yang sangat banyak untuk menghasilkan prediksi yang akurat.
- d) Memerlukan proses pelatihan model yang cukup lama.

Untuk *time series analysis* (ARIMA), mempunyai kelebihan sebagai berikut (Hagen, 2006):

- a) Mudah dalam pembentukan modelnya.
- b) Lebih cepat dalam pembentukan model, tidak perlu pelatihan seperti ANN.
- c) Hasilnya mudah diinterpretasikan, karena koefisien-koefisien model diketahui, sehingga dapat dilihat pengaruh masing-masing *predictor* terhadap hasil keluaran model.

Selain memiliki kelebihan, *time series analysis* (ARIMA) juga memiliki kekurangan sebagai berikut (Hagen, 2006):

- a) Secara umum lebih tidak akurat dibandingkan model ANN.
- b) Tidak dapat menangkap hubungan fungsional yang belum diketahui antara variabel independen dengan variabel dependen / tidak dapat menangkap hubungan antar variabel yang belum memiliki teori yang melandasinya.